

UNIVERSIDADE FEDERAL DO PARANÁ

JAIR JACOMO BERTUCINI JUNIOR

**ANÁLISE DE ALTERAÇÕES EM ÁREAS RURAIS POR MEIO DA CODIFICAÇÃO
BINÁRIA DE SÉRIES TEMPORAIS DE IMAGENS LANDSAT**

CURITIBA-PR

2017

JAIR JACOMO BERTUCINI JUNIOR

**ANÁLISE DE ALTERAÇÕES EM ÁREAS RURAIS POR MEIO DA CODIFICAÇÃO
BINÁRIA DE SÉRIES TEMPORAIS DE IMAGENS LANDSAT**

Tese apresentada como requisito parcial à obtenção do grau de Doutor em Ciências Geodésicas no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra, da Universidade Federal do Paraná.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno

CURITIBA-PR

2017

B552

Bertucini Junior, Jair Jacomo

Análise de alterações em áreas rurais por meio da codificação binária de séries temporais de imagens Landsat. / Jair Jacomo Bertucini Junior. – Curitiba, 2017.

123f. : il. [algumas color.]; tabs. : color. : 30 cm.

Tese (doutorado) - Universidade Federal do Paraná, Setor de Ciências da Terra, no curso de Pós-Graduação em Ciências Geodésicas.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno

Bibliografia: p.118-123.

1. Landsat (Satélites). I. Sensoriamento remoto. II. Centeno, Jorge Antonio Silva. III. Título.

CDD 526.982



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
Setor CIÊNCIAS DA TERRA
Programa de Pós-Graduação CIÊNCIAS GEODÉSICAS

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em CIÊNCIAS GEODÉSICAS da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **JAIR JACOMO BERTUCINI JUNIOR** intitulada: **ANÁLISE DE ALTERAÇÕES EM ÁREAS RURAIS POR MEIO DA CODIFICAÇÃO BINÁRIA DE SÉRIES TEMPORAIS DE IMAGENS LANDSAT**, após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 09 de Junho de 2017.



JORGE ANTONIO SILVA CENTENO

Presidente da Banca Examinadora (UFPR)



FLAVIO ANDRE CECCHINI DEPPE

Avaliador Externo (SIMEPAR)



ALVARO MURIEL LIMA MACHADO

Avaliador Interno (UFPR)



HIDEO ARAKI

Avaliador Interno (UFPR)



CHRISTEL LINGNAU

Avaliador Externo (UFPR)

Dedico à toda minha família em
especial à minha esposa Cláudia e
aos nossos filhos
Otávio e Maria Tereza.
Aos meus pais
Hidetaka e Terezinha.
Ao meu orientador Prof. Centeno.

AGRADECIMENTOS

À Deus por nos dar a vida, nos dar a família e por nos permitir a segurança nas muitas viagens entre nossa casa e o estudo.

Ao Instituto Federal Catarinense, Campus Concórdia, por nos permitir o afastamento integral para realização desse trabalho.

Ao Grupo JPUPIN em especial ao Sr. José Pupin pela atenção dada e disponibilidade dos dados de campo.

Ao professor Jorge Centeno pela dedicação e paciência na orientação dos trabalhos além dos ensinamentos na vida acadêmica.

Aos professores do programa de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, especialmente aqueles que estiveram diretamente envolvidos no nosso ensino.

A todos os colegas de curso que de uma forma ajudaram, em especial à Luciana Maria da Silva e ao Gabriel Henrique de Almeida Pereira, que sempre estiveram próximos e nos ensinando algo novo para quem já não é tão novo assim.

“Porque me viste Tomé creste;
bem-aventurados os que não viram e
creram”.
(Jesus Cristo).

RESUMO

As imagens LANDSAT possuem resolução espacial e temporal compatíveis que permitem a detecção de alterações no uso da terra no curso de vários anos. Nessa tese foi desenvolvido um método que permite fazer a análise de uma série anual de imagens, bem como a comparação interanual para a detecção de alterações nas áreas de cultivo. Foi feita a limiarização das imagens do Índice de vegetação por Diferença Normalizada (NDVI) pelo método de Otsu para análise das alterações da fenologia nos alvos agrícolas. O resultado desta etapa é uma série de imagens binárias para cada ano estudado no período de 2013 a 2015 para os meses de maio a dezembro. As imagens binárias foram combinadas, formando uma nova imagem de oito bits para cada ano. A classificação das imagens multitemporais de cada ano foi feita com o emprego de dois métodos. No primeiro através da classificação não supervisionada (*Clusters*) que gerou três imagens, uma para cada ano. Essas imagens foram então comparadas por um método desenvolvido nesse trabalho chamado Análise de Detecção de Mudanças Interanuais (ADMI). No segundo método foi feita combinação das três imagens multitemporais, uma em cada canal RGB, resultando uma imagem colorida que foi classificada de forma supervisionada pelos métodos da Mínima Distância Euclidiana e pela Máxima Verossimilhança. Os resultados mostraram que a codificação binária do índice NDVI permite descrever os ciclos de cultivo ao longo do ano e detectar alterações interanuais. O método desenvolvido nesse trabalho denominado Análise de Detecção de Mudanças Interanuais (ADMI), permitiu analisar a variação do uso da terra nas áreas estudadas para os três anos através da codificação das imagens multitemporais classificadas.

Palavras-chave: Detecção de alterações, Codificação binária, NDVI, SAVI, Limiarização de imagens.

ABSTRACT

LANDSAT images have high spatial and time resolution which allows performing land use change detection along many years. In this thesis a method has been developed which allows analyzing a series of annual images, as well as comparing inter-annual ones for change detection in croplands. The Normalized Difference of Vegetation Index (NDVI) was computed for each image and they were thresholded by the Otsu Method for the analysis of the phenology of the agricultural land target. The results of that stage are a series of binary images for each year including the months between May through December for 2013 to 2015. The binary images were combined, building a new 8 bits image for each year. The classification of the multi-temporal images of each year was made using two methods. This first one was the unsupervised classification (based on the use of clustering algorithms) which generated three images, one for each year. They were then compared through a method developed in this work called Inter-annual Detection Change Analysis (ADMI – *Análise de Detecção de Mudanças Interanuais*). In the second method the three multi-temporal images were combined as single channels of a RGB image, resulting in a color image which was classified with the supervised methods of the minimum Euclidean distance and the maximum likelihood. The results have shown that the binary coding of NDVI index allows describing the growing stages of vegetation along the year and detecting inter-annual changes. The method developed in the present work called Inter-annual Detection Change Analysis (ADMI – *Análise de Detecção de Mudanças Interanuais*) allowed analyzing the land use variations in the areas in the three years period.

Key-words: Change detection; Binary coding, NDVI; SAVI; Thresholding of the images.

SUMÁRIO

1. INTRODUÇÃO	13
1.1 OBJETIVOS.....	14
1.1.1 Objetivo principal.....	14
1.1.2. Objetivos específicos.....	14
1.2 APLICAÇÕES.....	15
2. REVISÃO DE LITERATURA	17
2.1 CORREÇÃO RADIOMÉTRICA.....	19
2.1.1 Redução do espalhamento atmosférico	20
2.2 CORREÇÃO GEOMÉTRICA	20
2.2.1 Correção com pontos de apoio	21
2.2.3 Avaliação do produto.....	23
2.3 MÉTODOS DE DETECÇÃO DE ALTERAÇÕES	23
2.3.1 Comparação Pós-classificação:	25
2.3.2 Comparação direta das imagens originais:	25
2.3.3 Métodos de uso conjunto de todas as imagens	27
2.3.4 Composição multitemporal de três datas	28
2.3.5 Discussão.....	28
2.3.6 Detecção de alterações de forma contínua (CCDC)	29
2.4 LIMIAZIZAÇÃO DE IMAGENS	32
2.4.1 Método Otsu.....	33
2.5 MONITORAMENTO TEMPORAL DE ÁREAS AGRÍCOLAS.....	35
2.5.1 Vegetação	35
2.5.2 Solo	36
2.5.3 Água.....	38
2.6 ÍNDICES DE VEGETAÇÃO	38
2.6.1 Índice de Vegetação da razão simples (Simple Ratio - SR).....	40
2.6.2 Índice de Vegetação por Diferença Normalizada (NDVI)	40
2.6.3 Índice de Vegetação Ajustado para o Solo (SAVI)	42
2.6.4 Índice de Vegetação Realçado (EVI)	42
2.6.5 Índice de Área Foliar (IAF)	43
3. ÁREA DE ESTUDO.....	45

3.1 FAZENDA MARABÁ.....	48
3.2 CARACTERIZAÇÃO DAS CULTURAS ESTUDADAS.....	50
3.2.1 Cultura do algodão	50
3.3.2 Cultura da soja	52
3.3.2 Rotação de culturas	54
4. MATERIAIS	55
4.1 IMAGENS LANDSAT	55
4.2 SOFTWARES USADOS PARA O PROCESSAMENTO DAS IMAGENS	56
5. METODOLOGIA.....	59
5.1 PRÉ-PROCESSAMENTO DAS IMAGENS.....	60
5.1.1 Recorte das imagens.....	60
5.1.2 Preenchimento de linhas perdidas nas imagens LANDSAT 7.....	60
5.1.3 Correção geométrica	62
5.1.4 Correção atmosférica	63
5.2 CÁLCULO DOS ÍNDICES DE VEGETAÇÃO	63
5.2.1 Cálculo do índice de vegetação por diferença normalizada (NDVI)	64
5.2.2 Cálculo do índice de Vegetação Ajustado para o Solo (SAVI)	64
5.3 SEGMENTAÇÃO DE VEGETAÇÃO	65
5.4 CODIFICAÇÃO BINÁRIA: SÉRIES ANUAIS.....	66
5.4.1 Análise anual.....	67
5.4.2 Composição multitemporal	68
5.5 VEGETAÇÃO PERMANENTE.....	69
5.5.1 Mata galeria ou ciliar	69
5.5.2 Cerrado	69
5.6 CLASSIFICAÇÃO DAS IMAGENS	70
5.6.1 Classificação anual.....	70
5.6.2 Análise de Detecção das Mudanças Interanuais.....	71
5.6.3 Classificação da imagem multianual do índice NDVI	72
5.6.4 Avaliação da classificação.....	72
6. RESULTADOS	74
6.1 CORREÇÃO RADIOMÉTRICA.....	74
6.2 CORREÇÃO GEOMÉTRICA	76

6.3 IMAGENS BINÁRIAS.....	79
6.4 IMAGENS MULTITEMPORAIS	83
6.4.1 Característica das culturas nas imagens multitemporais.....	87
6.5 ANÁLISE PÓS-CLASSIFICAÇÃO	90
6.5.1 Classificação anual (2013 a 2015)	90
6.5.2 Classificação pela detecção das mudanças interanuais (DMI)	96
6.5.3 Validação da análise de pós-classificação com a verdade de campo.....	99
6.6 ANÁLISE MULTIANUAL	104
6.6.1 Classificação da imagem multianual da imagem NDVI	106
6.6.2 Validação da classificação da análise multianual com a verdade de campo..	111
6.7 COMPARAÇÃO DOS MÉTODOS.....	113
7. CONCLUSÕES	116
RECOMENDAÇÕES.....	117
REFERENCIAS.....	118

1. INTRODUÇÃO

Áreas agrícolas são altamente dinâmicas e têm variações fenológicas com estágios diferentes de crescimento ou de manejo. A dinâmica é ainda maior quando os campos agrícolas são submetidos a rodízio de culturas por práticas conservacionistas ou de uso diferenciados. A rotação de culturas objetiva não só intercalar as culturas, mas também os herbicidas aplicados. Ela também promove a absorção de nutrientes e a distribuição radicular ao longo do perfil em camadas diferentes. Isto tem consequências na produtividade e preservação dos solos.

O sensoriamento remoto é uma ferramenta fundamental para o estudo de áreas agrícolas. Através do uso de uma imagem multiespectral é possível estimar a área coberta por diferentes culturas em uma determinada data, analisando as diferenças na resposta espectral das mesmas. Comparando duas imagens de uma mesma área para um mesmo mês em anos diferentes é possível determinar as alterações sofridas entre os anos.

Porém, as áreas agrícolas não se diferenciam apenas pelas diferenças espectrais entre culturas ou fases de crescimento. Algumas culturas apresentam grande dinâmica temporal como característica, além das práticas de rotação que podem imprimir uma dinâmica particular à cobertura do solo. Se, em termos espectrais algumas espécies vegetais são similares, muitas vezes estas mesmas espécies podem ser diferenciadas devido a seus diferentes ciclos de crescimento, culturas de verão, culturas anuais, espécies perenes. Para estudar esta dinâmica, torna-se necessário analisar uma série de imagens que cobre diferentes fases do ciclo de cada cultura, obtidas ao longo do ano, o que gera uma grande quantidade de dados a serem processados, podendo ser estendida a vários anos ou safras. As imagens de satélite LANDSAT são uma das mais importantes fontes de dados para o estudo da evolução de diferentes tipos de cobertura do uso do solo, devido à vasta quantidade de imagens disponíveis no seu acervo histórico que é disponibilizado de forma gratuita. O acervo LANDSAT coloca à disposição imagens com um intervalo de tempo que permite a análise das variações do uso do solo ao longo de anos e décadas. Isso se deve às passagens na mesma órbita e ponto que ocorrem a cada 16 dias para os satélites LANDSAT 7 e LANDSAT 8. Com a combinação das imagens geradas pelos dois satélites a resolução temporal foi reduzida para 8 dias melhorando as condições de manipulação das imagens.

A resolução espacial de 30m das imagens LANDSAT é considerada adequada para trabalhos que visam o estudo de detecção de alterações em áreas agrícolas e florestais para longos períodos, anos ou décadas. O trabalho de Zhu e Woodcock (2014) descreve que atualmente estão sendo desenvolvidos novos algoritmos de detecção de alterações usando imagens LANDSAT, de pelo menos uma data por ano para encontrar mudanças no uso do solo, necessitando que as imagens sejam de uma mesma época do ano para minimizar as influências de diferença de fenologia e ângulo do sol.

O problema abordado nesta pesquisa é verificar e determinar as alterações em talhões de culturas agrícolas analisando longas séries temporais de imagens LANDSAT. Para isto, o crescimento da vegetação, descrito pelo índice de vegetação é monitorado usando a codificação binária da série de dados. O trabalho se desenvolveu em uma área de agricultura onde as principais culturas são algodão, e soja, sendo que em alguns casos estas culturas são as únicas cultivadas ao longo do ano e em alguns casos é feita a rotação de ambas. A hipótese a ser verificada no trabalho é que o ciclo de culturas e as alterações na cobertura do solo ao longo do tempo podem ser representados com a codificação binária de uma longa série de imagens LANDSAT.

1.1 OBJETIVOS

1.1.1 Objetivo principal

Desenvolver um modelo de detecção de mudanças empregando imagens LANDSAT para determinar e comparar as assinaturas espectrais de duas culturas agrícolas (algodão e soja) além da rotação entre as mesmas.

1.1.2. Objetivos específicos

- a) Desenvolver um método de codificação binária para análise multitemporal;
- b) Avaliar o uso dos índices de vegetação NDVI e SAVI para a codificação binária;
- c) Avaliar a capacidade de detectar diferenças nos ciclos de culturas com uma série temporal de imagens;

- d) Comparar cinco métodos de classificação para as imagens codificadas utilizando o índice de vegetação NDVI.

1.2 APLICAÇÕES

As áreas agrícolas podem ser monitoradas por imagens de satélite, pois cada alvo apresenta características físicas que mudam sua resposta espectral. O monitoramento da agricultura em áreas de intensa exploração visa o acompanhamento das mesmas em função das principais características do solo (fertilidade e textura), das culturas implementadas a cada ciclo ou ano agrícola. O monitoramento das áreas cultivadas permite que o produtor tenha as informações da distribuição das culturas no espaço e no tempo, o que possibilita a tomada de decisão quanto ao uso para as próximas safras, através da integração com banco de dados implantados em Sistemas de Informação Geográfica.

O uso dessas informações pode ser feito também por cooperativas, órgãos de fomento agrícola, bem como a fiscalização pelas agências reguladoras e financiadoras. Outra finalidade importante corresponde à verificação do intervalo de tempo necessário para o vazio sanitário obrigatório, como é o caso da cultura do algodão. Como o método proposto é feito por sensoriamento remoto, a visita em campo se restringe a uma permanência menor ou feita por amostragem não necessitando se percorrer uma área de grandes dimensões o que torna a aplicação útil como é o caso da região estudada.

A agricultura pode ser monitorada de forma periódica e repetitiva através de imagens de sensoriamento remoto que permitem verificar com qualidade a dinâmica do ciclo natural das diferentes espécies cultivadas. Para isso é necessário conhecer não somente a assinatura espectral das espécies, como também as relações entre as propriedades físicas e morfológicas de um dossel agrícola, em função de seu desenvolvimento. O conhecimento do calendário agrícola e do clima local é primordial para a identificação do desenvolvimento de cada espécie estudada visando conhecer e identificar as mudanças ocorridas. Assim, é possível usar imagens de satélite em diferentes datas para monitorar o ciclo vegetativo de cada cultura e as mudanças no uso da terra.

Conforme Singh (1989), as detecções de alterações são úteis em diversas aplicações, entre elas, o monitoramento da agricultura, a avaliação do desmatamento,

o estudo de mudanças na fenologia da vegetação, mudanças sazonais na produção de pastagens, avaliação de danos por pragas, detecção do *stress* das culturas e outras mudanças ambientais. Dessa maneira é possível implementar um modelo de detecção contínua que permita fazer o monitoramento do uso de solo em lavouras usando imagens de sensoriamento remoto.

2. REVISÃO DE LITERATURA

O sensoriamento remoto é uma fonte de dados com informações atualizadas de cobertura da terra, tendo a detecção de alterações se tornado uma grande aplicação devido à cobertura repetitiva em intervalos de tempo curtos e pela qualidade da imagem (MAS, 1999). Uma das principais contribuições do sensoriamento remoto para o monitoramento e gerenciamento ambiental é a possibilidade de efetuar estudos comparativos de imagens obtidas em datas diferentes, estudos multitemporais. Dentro desta atividade ganha destaque o programa LANDSAT por oferecer um rico acervo histórico de imagens desde os anos 70, fonte de dados que permite analisar alterações temporais, para um grande período se comparada com as imagens de alta resolução espacial que podem ser adquiridas atualmente.

De acordo com Coppin et al. (2004), as técnicas baseadas em análise de dados multitemporais e multiespectrais provenientes de sensores orbitais têm demonstrado potencial como um meio para detectar, identificar e monitorar as alterações do ecossistema independentemente de seus agentes causais.

Mas (1999) também destaca que a utilização de séries temporais de sensoriamento remoto é afetada pelas mudanças nos valores de radiância e radiação causada por fatores tais como diferenças nas condições atmosféricas, na umidade do solo e em ângulos solares, entretanto relata que pode ser extremamente difícil obter dados multitemporais da mesma época do ano, particularmente nas regiões tropicais, onde a cobertura de nuvens é comum, sendo necessário trabalhar com imagens de anos diferentes para um mesmo período.

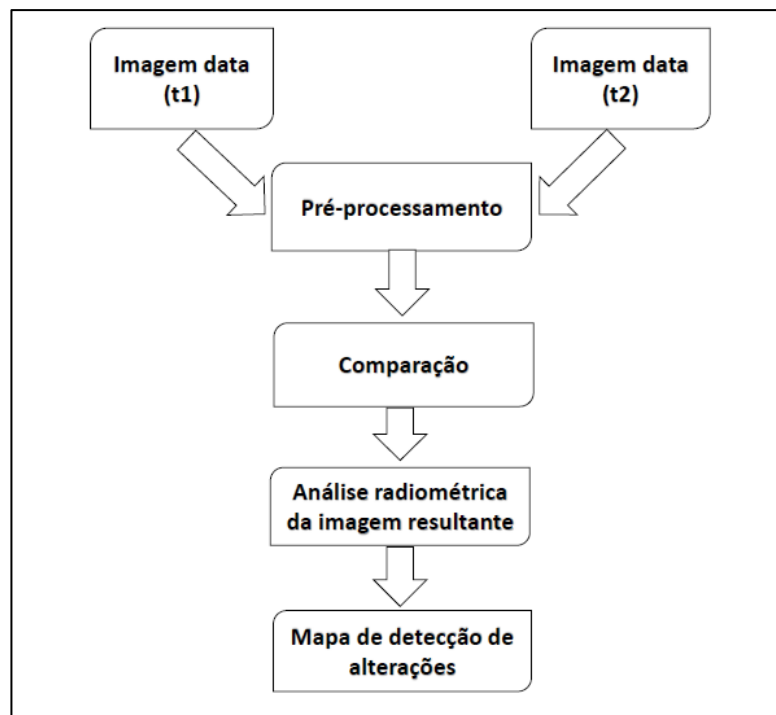
Trabalhando em áreas agrícolas, Portillo (2008), descreve que os dados obtidos em sensoriamento remoto são instrumentos de grande utilidade para obtenção de informações em relação ao uso da terra, especialmente em rotação de culturas, devido os mesmos possuírem uma cobertura sinóptica e repetitiva. O autor destaca que a análise multitemporal de uma área agrícola numa dada época permite obter uma série histórica que facilita a identificação dos alvos nas imagens de satélite. Para tanto é importante que se considere o número de imagens e a data das mesmas no momento da escolha.

Na região do semiárido do nordeste brasileiro, Batista (2011) trabalhou com a detecção de mudanças empregando imagens multitemporais do satélite LANDSAT 5

TM obtendo bons resultados com baixo custo. O trabalho permitiu detectar a dinâmica da cobertura e uso do solo, tanto sazonais como anuais.

De acordo com Chen (2008), a comparação entre imagens multitemporais deve partir de uma série de procedimentos que consiste em: pré-processamento (correção geométrica e radiométrica), comparação pixel-pixel e limiarização da imagem para posterior análise (FIGURA 1).

FIGURA 1 - ESQUEMA DAS ETAPAS PARA PREPARO DAS IMAGENS QUE PERMITE OBSERVAR O PADRÃO DE DETECÇÃO DE MUDANÇA



FONTE: adaptado de Chen (2008).

A comparação descrita por Chen (2008) visa produzir uma imagem adicional onde as diferenças entre as duas imagens adquiridas podem ser destacadas por meio de operadores matemáticos diferentes escolhidos partindo de diferentes técnicas. O processo de comparação de imagens obtidas em datas diferentes passa então pelos seguintes passos:

- a) Seleção das imagens;
- b) Correção radiométrica;
- c) Correção geométrica;
- d) Comparação das imagens (detecção de alterações);

2.1 CORREÇÃO RADIOMÉTRICA

Os dados espectrais registados pelos sensores orbitais são influenciados por uma variedade de fatores relacionados com a cena observada. Entre eles podem-se incluir os efeitos de absorção e espalhamento atmosférico, além de variações causadas pela iluminação da geometria entre o sensor e o alvo tornando as imagens sem utilidade para uso do estudo de variações, necessitando que seja feita uma correção radiométrica (FRANKLIN e GILES, 1995).

Chander et al. (2009), descrevem que a capacidade de detectar e quantificar as mudanças no ambiente terrestre varia em função dos tipos de sensores que devidamente calibrados podem fornecer medidas consistentes partindo dos dados coletados. O mesmo autor destaca que uma proposta para a correção radiométrica se faz pela conversão do nível de cinza (NC) em cada pixel para radiância, que pode ser calculada para os sensores LANDSAT pela Equação 1 descrita abaixo.

$$L_{\lambda} = \left(\frac{L_{MAX} - L_{MIN}}{255} \right) \times NC + L_{MIN} \quad (1)$$

Onde:

L_{MAX} e L_{MIN} : são as constantes de calibração de cada banda nos sensores;

NC é o nível de cinza.

A correção atmosférica pode ser realizada partindo de diversas metodologias. Uma delas é através da utilização do *LANDSAT Ecosystem Disturbance Adaptive* (LEDAPS) como ferramenta, descrito em (Masek et al., 2006; Vermote et al., 1997) em que os valores brutos do contador digital são convertidos em reflectância de superfície (SR) e Brilho Temperatura (BT). De acordo com Chander et al. (2009) é possível reduzir a variabilidade do registro de energia para uma determinada cena através da conversão da radiância espectral no sensor (L_{λ}) para reflectância estratosférica (ρ) no topo da atmosfera, como é demonstrado na Equação 2.

$$\rho = \pi \cdot L \cdot D^2 / (ESUN \cdot \cos(\theta)) \quad (2)$$

Onde:

ρ - reflectância monocromática (adimensional);

ESUN - irradiância solar exoatmosférica média ($\text{W. m}^{-2}. \text{mm}^{-1}$);

D - distância sol-terra (unidade astronômica);

Θ - ângulo solar zenital (graus).

2.1.1 Redução do espalhamento atmosférico

Segundo Chavez Jr. (1988), existem vários métodos para eliminar os efeitos da dispersão atmosférica, incluindo a técnica conhecida como subtração de objeto escuro (*Dark Object Subtraction* - DOS). Essa técnica se caracteriza pela correção usando o NC (nível de cinza) estimando o espalhamento atmosférico para as bandas, partindo de um modelo que utiliza como valor de entrada o espalhamento de apenas uma banda. Esse método assume que existe uma alta probabilidade de existir pelo menos, alguns pixels pretos (0% de reflectância) em uma imagem em função da existência de sombras devido à topografia ou nuvens na imagem. Teoricamente não é detectada qualquer radiação nesses locais de sombra, e um valor para o nível de cinza (NC) igual a zero pode ser atribuído. No entanto, devido ao espalhamento atmosférico, essas áreas sombreadas não serão completamente escuras, com maior interferência nos comprimentos de onda mais curtos. Dessa forma é necessário que o nível de cinza deva ser subtraído para remover o espalhamento de primeira ordem.

Chavez Jr. (1988) argumenta que não é adequado subtrair os valores mínimos encontrados em cada banda da imagem porque estes valores podem superestimar a correção nas demais bandas. Dessa forma, o autor propõe um modelo para o cálculo do espalhamento em cada banda, partindo apenas do valor do nível de cinza de menor frequência encontrada na banda com menor comprimento de onda, permitindo identificar a condição atmosférica presente no momento da obtenção da imagem.

Dessa maneira, o nível de cinza do pixel mais escuro permite classificar a condição atmosférica da obtenção da imagem em: muito limpa até opaca. Partindo do modelo de espalhamento relativo, é possível calcular o espalhamento em cada banda espectral.

2.2 CORREÇÃO GEOMÉTRICA

As imagens de satélite são obtidas com erros sistemáticos provenientes do processo de aquisição. Essas distorções, segundo Silva et al. (2012) são devido à plataforma do satélite (velocidade, altitude e posição), ao instrumento, ao tipo de sensor (varredura mecânica ou eletrônica) e ao modelo da Terra. A correção geométrica permite a redução desses erros. No caso do presente estudo, que se trata de uma avaliação multitemporal, o registro deve ser feito com outras imagens, pois permite interpretar a resposta espectral de uma série para uma mesma posição no espaço.

A função dos algoritmos de correção geométrica é reorganizar os pixels da imagem em relação a um determinado sistema de projeção cartográfica (NOVO, 2010). Na correção geométrica são empregados os dados do cabeçalho da imagem referentes às efemérides da trajetória do sensor orbital (fornecidos), que são associados com pontos de apoio medidos no terreno.

2.2.1 Correção com pontos de apoio

Uma correção geométrica mais acurada é obtida com ajuda de informação local, com pontos de apoio. De acordo com Lee et al. (2012) os pontos de apoio são feições homólogas identificáveis no terreno e na imagem, com coordenadas conhecidas na imagem e no sistema de referência adotado. A distribuição adequada dos mesmos deve considerar as distorções que podem existir nas imagens orbitais e as transformações geométricas usadas nessas.

No caso do registro de imagens, os pontos de apoio são pontos visíveis e positivamente identificáveis nas duas imagens. Assim sendo, estes pontos têm coordenadas conhecidas na imagem a ser corrigida (ou ajustada) e na imagem de referência.

O modelo polinomial de primeira ordem, descrito pelas equações 3 e 4, pode ser aplicado no registro de imagens LANDSAT, pois as imagens, obtidas pelo mesmo sensor, possuem geometria muito similar, são obtidas de locais muito próximos à mesma altura, sendo necessário apenas um ajuste fino.

$$c = a_0 + a_1x + a_2y \quad (3)$$

$$l = a'_0 + a'_1x + a'_2y \quad (4)$$

Onde:

c ; l = são as coordenadas no sistema de referência (extraídas da imagem base);

X , Y = são as coordenadas da imagem bruta; a_1 , a_2 , a'_1 , a'_2 , a_0 ; a'_0 = são os parâmetros de transformação a serem determinados, mediante o cálculo de ajustamento pelo método dos mínimos quadrados.

2.2.2 Reamostragem

A imagem corrigida é construída aplicando o mapeamento inverso. Para isto é criada uma imagem de saída vazia. Esta imagem é varrida sistematicamente e para cada um de seus pixels é calculada a posição correspondente na imagem de entrada. Como as novas coordenadas calculadas geralmente não correspondem a números inteiros há necessidade de se fazer a interpolação, o que se conhece como reamostragem. Os métodos mais conhecidos são: vizinho mais próximo, bilinear e convolução cúbica.

No método do vizinho mais próximo, é atribuído ao pixel da imagem transformada o nível de cinza do pixel mais próximo. O valor do nível de cinza do pixel mais próximo apenas é transferido da imagem original para a imagem de saída.

No método da Interpolação bilinear são utilizados os valores dos quatro pixels vizinhos mais próximos à posição calculada do pixel na imagem original. Com eles são feitas duas interpolações lineares ao longo das linhas e uma ao longo das colunas, o que permite calcular um valor ponderado em função da distância do ponto aos quatro vizinhos. Segundo Novo (2010), a vantagem desse método de reamostragem em relação ao método vizinho mais próximo é a maior precisão e o desaparecimento de descontinuidades.

O método da convolução cúbica é o mais complexo, pois são utilizados 16 pixels (vizinhança 4x4), para determinar o valor do pixel reamostrado. Este modelo utiliza uma aproximação polinomial cúbica para interpolar os valores digitais, a reamostragem é feita por uma função polinomial em cada direção (X , Y) baseada nos valores da imagem original.

2.2.3 Avaliação do produto

Após a aplicação do modelo de transformação geométrica aos pontos de apoio é possível avaliar a qualidade do modelo analisando a diferença entre os valores preditos (c', l') e os medidos (c, l). Dessa forma os resíduos podem ser checados, sendo o primeiro dado pela diferença em colunas ($c' - c$) e o segundo pela diferença em linhas ($l' - l$). A diferença total, ou distância entre o ponto lido e o ponto predito, leva em conta as duas direções e é calculada como é expresso na Equação 5 (IBGE, 2001).

$$Dif = \sqrt{(c' - c)^2 + (l' - l)^2} \quad (5)$$

Conforme IBGE (2001), os resíduos calculados para cada ponto de apoio são muito úteis para avaliar a transformação. Esses parâmetros expressos em pixels são ainda importantes indicativos da acurácia da transformação, pois revelam a diferença entre o valor correto e o valor calculado. Um valor representativo para todo o conjunto de n pontos pode ser obtido aplicando o conceito de *Root Mean Square Error* (RMSE), mostrado na Equação 6.

$$RMSE = \sum_{i=1}^n \sqrt{(Difi)^2} \quad (6)$$

Em uma situação ideal, a diferença entre os valores modelados e os observados deve ser baixo (RMSE) para que a correção geométrica seja considerada aceitável. Geralmente se objetiva obter valores abaixo de um pixel.

2.3 MÉTODOS DE DETECÇÃO DE ALTERAÇÕES

Uma variedade de técnicas de detecção de mudanças são propostas dentro do escopo do sensoriamento remoto, algumas delas serão descritas a seguir, concentrando-se nos métodos baseados em pixel, que são geralmente usados quando se trata imagens LANDSAT de média resolução espacial. Na literatura também são encontradas diversas compilações e revisões de literatura a respeito deste tema como, por exemplo, Singh (1989). Este autor classifica os métodos de

detecção de alterações baseada em pixel em duas grandes classes: a) comparação de duas imagens temáticas obtidas independentemente e b) comparação direta das imagens originais em duas datas. Um estudo similar, considerando imagens de satélite pode também ser encontrado em Coppin e Bauer (1996). Deer (1999) considera uma nova categoria onde podem ser enquadrados métodos mais recentes como aqueles baseados em sistemas especialistas, lógica fuzzy e redes neurais, e onde também podem ser incluídos aqueles baseados na segmentação ou objeto. A oferta de levantamentos bibliográficos é vasta na literatura, o que comprova o alto interesse científico que o tema provoca, por exemplo Ashok (2014) ou Radke et al. (2005).

Seguindo a classificação clássica apresentada por Singh (1989) e Lu et al. (2003), os métodos mais tradicionais podem ser divididos em:

- a) Comparação Pós-classificação:
 - a. Classificação supervisionada independente;
 - b. Classificação não supervisionada;
 - c. Classificação com algoritmo de maximização do valor esperado (EM).
- b) Comparação direta das imagens originais:
 - a. Operações aritméticas (diferença, razão de bandas);
 - b. Método de regressão;
 - c. Análise do vetor de mudança;
 - d. Subtração do fundo;
 - e. Métodos de uso conjunto de todas as bandas:
 - i. Método de componentes principais;
 - ii. *Tasseled cap*;
 - iii. *Gramm-Schmidt*;
 - iv. Agrupamento.
- c) Método de mistura espectral e outros.

Outros métodos são listados em Lu et al. (2003). Estes métodos serão sucintamente apresentados a seguir, para fundamentar a escolha do método usado neste trabalho.

2.3.1 Comparação Pós-classificação:

Neste conjunto de métodos cada imagem é tratada independentemente como um problema de classificação. Assim, todas as bandas de interesse são usadas para produzir um mapa temático da data correspondente. Quando se lida com duas datas, então duas imagens temáticas serão obtidas independentemente. Recomenda-se usar o mesmo método de classificação para as duas imagens, para evitar erros sistemáticos que dependam do método. A classificação supervisionada é a mais usada, por exemplo, com o método da Máxima Verossimilhança Gaussiana, ou também, com as Redes Neurais Artificiais.

Uma variação consiste em executar a classificação não supervisionada de cada imagem e comparar os resultados dos dois agrupamentos.

A detecção “EM” é um método baseado em classificação usando um algoritmo de maximização do valor esperado que analisa a probabilidade conjunta a priori da ocorrência das duas classes nas datas diferentes. Estas probabilidades são estimadas a partir das imagens temáticas (LU et al., 2003).

2.3.2 Comparação direta das imagens originais:

Este grupo de métodos tem como característica o fato de comparar diretamente as imagens originais, não o produto de uma classificação. As imagens obtidas em duas datas na mesma banda espectral são confrontadas para detectar diferenças entre as mesmas que indicariam mudanças na cobertura da Terra.

A maneira mais simples de comparar duas imagens (A_t imagem na data t e A_0 imagem de referência) é através de operações aritméticas entre bandas. Estas operações podem ser a diferença, conforme descrito na Equação 7, onde k é uma constante para produzir valores positivos (SINGH, 1989). Se não houve mudanças ao longo do tempo, então o valor resultante será nulo. Valores altos caracterizam alterações espectrais.

$$C = A_t - A_0 + k \quad (7)$$

Ou a razão entre bandas, segundo a Equação 8. Se os valores digitais das duas imagens são similares, a razão entre bandas teria valores próximos da unidade.

$$C = A_t / A_0 + k \quad (8)$$

Uma vez calculado o resultado, nos dois casos, o problema final é delimitar a fronteira entre “alteração” e não alteração, o que é feito por limiarização (Equação 9).

$$\begin{array}{ll} \text{SE } C(i,j) > T & \text{ENTÃO } \textit{alteração} \\ \text{CASO CONTRÁRIO} & \textit{não alteração} \end{array} \quad (9)$$

A análise do vetor de mudança é uma extensão do método da diferença para mais de uma faixa espectral. Quando se dispõe de mais de uma banda espectral, uma imagem multiespectral com N-bandas, é possível calcular a diferença em cada banda segundo a Equação 3, do que resultariam N imagens de diferença. Estas diferenças podem ser agrupadas em um vetor V, segundo a Equação 10.

$$V = [C_{t1} \ C_{t2} \ C_{t3} \ \dots \ C_{tN}] \quad (10)$$

Este vetor fornece duas informações a respeito das alterações. A primeira é traduzida pela norma do vetor, que indica a intensidade da alteração em cada pixel. A direção do vetor informa a respeito da natureza da alteração, pois é altamente influenciada pelas bandas selecionadas e da maneira em que o valor do pixel foi alterado em cada uma delas.

No método da regressão, parte-se da suposição de que, se não ocorrem alterações ao longo do tempo, as imagens de duas datas diferentes serão altamente correlacionadas e podem ser descritas por uma relação linear, como na Equação 11.

$$A_t = a * A_0 + b \quad (11)$$

Os valores dos parâmetros do modelo linear são obtidos pelo método dos mínimos quadrados, o que permite obter uma estimativa da imagem no tempo t como indica a Equação 12.

$$\hat{A}_t = a * A_0 + b \quad (12)$$

As diferenças temporais serão caracterizadas por grandes diferenças entre o valor previsto e o observado como mostra a Equação 13.

$$C = A_t - \hat{A}_t \quad (13)$$

Aqui, novamente, é necessário aplicar um limiar para caracterizar diferenças significativas.

Em teoria, áreas que não sofrem alterações temporais têm valores digitais muito próximos do fundo. Estas variações podem ser aproximadas por uma imagem de fundo obtida, por exemplo, aplicando um filtro passa-baixas à imagem original. Uma nova imagem é produzida através da subtração da imagem de fundo da imagem analisada (COPPIN e BAUER, 1996).

2.3.3 Métodos de uso conjunto de todas as imagens

Neste grupo de técnicas, todas as bandas de duas imagens multiespectrais são combinadas para produzir uma única imagem, com o dobro de bandas espectrais. Esta nova imagem combinada é então analisada.

Uma das opções é aplicar a transformação das componentes principais a este conjunto. A transformação das componentes principais assume que existe grande correlação entre as bandas espectrais próximas. Considerando o espaço formado pelo conjunto de bandas originais, a transformação das componentes principais consiste em aplicar uma transformação de rotação a este sistema para obter um novo sistema no qual as novas bandas tenham correlação mínima. Uma análise cuidadosa das imagens resultantes é efetuada para detectar as alterações, visto que elas podem estar visíveis em componentes de ordem maior. De acordo com Mas (1999), a informação que é comum às duas bandas será mapeada para a primeira componente principal e a informação que é única para qualquer uma das duas bandas (as alterações) é mapeada para as componentes de ordem maior. Um exemplo de aplicação é encontrado em Richards (1984). Uma abordagem similar foi proposta com base na transformação *tasseled cap* e pode ser vista em Coppin et al. (1999). Uma abordagem similar se baseia na transformação Gramm-Schmidt transforma os vetores originais para um espaço ortogonal onde as diferenças são evidenciadas.

Uma solução mais simples, porém, trabalhosa em termos computacionais, é aplicar métodos de agrupamento ao conjunto de todas as bandas com a finalidade de encontrar regiões, ou clusters, associados a mudanças nas leituras digitais das bandas. É também possível efetuar a classificação supervisionada espectro-temporal, delimitando áreas de treinamento nas regiões de mudança (ROBERTS et al., 1997).

2.3.4 Composição multitemporal de três datas

A maioria dos estudos descritos acima utilizam duas datas para detectar alterações. Porém, o estudo também pode ser estendido a três datas fazendo a composição multitemporal das imagens. Conforme Batista (2011) a detecção de mudanças por composição multitemporal consiste na combinação RGB das datas analisadas colocando cada uma em um canal separadamente, resultando uma composição colorida cujas cores que podem ser relacionadas com as diferenças entre datas. Como resultado as cores são produtos das combinações RGB de cores que representam cada data. Essa técnica permite o uso de imagens multitemporais empregando o Índice de Vegetação por Diferença Normalizada (NDVI) ou o Índice de Vegetação Ajustado para o Solo (SAVI) para observar as mudanças em áreas de floresta e agricultura, permitindo analisar o comportamento temporal das mesmas.

De acordo com Kiel (2008), nas áreas onde ocorre as transformações é que se concentram as discrepâncias estatísticas em relação às que ficam inalteradas, ou com poucas mudanças. Uma desvantagem da classificação desse tipo de imagem multitemporal é devido à equivalência encontrada entre as feições espectrais e temporais, que a princípio podem parecer inseparáveis exigindo muito conhecimento de campo do analista para com as cenas que poderá incluir vários estágios e sistemas lógicos de decisão (COPPIN et al., 2004).

2.3.5 Discussão

Os métodos supracitados partem geralmente da premissa de que duas datas serão confrontadas para detectar as alterações e diferenças. Porém, estes métodos não são facilmente adaptáveis para seu uso com uma quantidade maior de datas. O método de composição multitemporal pode ser ampliado a mais do que três datas, formando uma imagem hipertemporal. O problema, neste caso, é caracterizar as

diferenças, visto que não é possível visualizar na tela do computador mais do que três datas simultaneamente.

Técnicas de agrupamento poderiam ser aplicadas a este novo conjunto de dados, porém, os agrupamentos resultantes seriam difíceis de interpretar, considerando a grande quantidade de possíveis combinações.

O método das componentes principais seria uma opção viável, uma vez que a informação comum estaria representada na primeira componente e as diferenças enfatizadas em outras de ordem maior. O problema é que, em se tratando de um grande número de imagens, as componentes a serem analisadas são muitas.

Neste sentido, novos métodos são necessários para aproveitar a riqueza do acervo de imagens hoje disponíveis, que refletem a evolução temporal com detalhe ao longo de décadas.

2.3.6 Detecção de alterações de forma contínua (CCDC)

Uma metodologia proposta para o estudo de alterações da cobertura ao longo do tempo de forma contínua é apresentada, por exemplo, em Zhu e Woodcock (2014), onde desenvolveram um método que consiste na detecção de alterações de forma contínua com a comparação de previsões feitas empregando um modelo baseado em observações isentas de nuvens. Teoricamente, uma única comparação entre duas datas diferentes seria suficiente para a detecção de mudanças. No entanto, não há precisão suficiente, pois há interferência devido à presença de nuvens, sombras, neve, neblina, fumaça, além de mudanças na umidade do solo que podem levar a inúmeros erros de falsos positivos na detecção de mudanças quando se utiliza uma única data para comparação. Os mesmos autores descrevem que o modelo de séries temporais do algoritmo CCDC deve conter 4 coeficientes e 12 “observações claras” (três vezes o número de coeficientes). A razão para escolher três observações isenta de nuvens, é que o algoritmo de CCDC utiliza três observações consecutivas para determinar se um pixel é alterado ou não, sendo suficiente para que o modelo de séries temporais possa responder se houve mudança.

De acordo com os autores esses algoritmos ainda têm limitações relacionadas à seleção de imagens LANDSAT ideais, como por exemplo, a necessidade das imagens serem de uma mesma época do ano para minimizar as influências de

diferença de fenologia e ângulo do sol. Podemos de um modo geral dividir as alterações em:

- a) Mudança intra-anual (FIGURA 2A), causada por uma vegetação com fenologia impulsionada por padrões sazonais de fatores ambientais como temperatura e precipitação;
- b) Mudança inter-anual gradual (FIGURA 2B), causada pela diferença entre os volumes pluviométricos entre os anos, o crescimento da vegetação ou mudança gradual no uso da terra com gestão ou degradação dos solos;
- c) Mudança abrupta (FIGURA 2C), causada pelo desmatamento, inundações, incêndios, insetos, urbanização, etc.

O modelo de série temporal contém componentes de sazonalidade, tendência, e quebras que capturam todas as três categorias de mudança de superfície (Equação 14). Os coeficientes do modelo são estimados pelo *Ordinary Least Squares* (OLS), método considerado rápido, com base no restante das “observações claras” do satélite LANDSAT.

$$\rho(i, x)_{OLS} = a_{0,i} + a_{1,i} \cos\left(\frac{2\pi}{T} X\right) + b_{1,i} \sin\left(\frac{2\pi}{T} X\right) + c_{1,i} X \quad (14)$$

$$\{T_{k-1}^* < X \leq T_k^*\}$$

Onde:

X - Data juliana;

I - Banda do LANDSAT;

T - Número de dias por ano ($T = 365$);

$a_{0,i}$ - Coeficiente de valor global para a banda LANDSAT;

$a_{1,i}; b_{1,i}$ - Coeficientes de variação intra-anual para a banda LANDSAT;

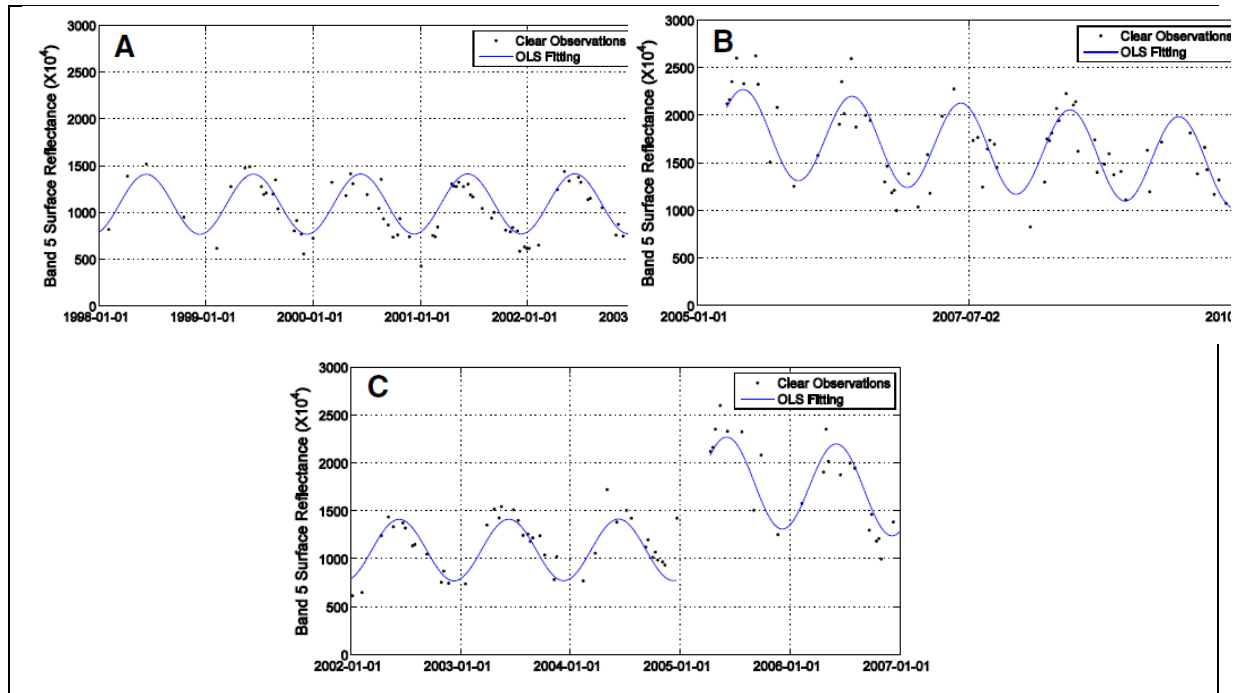
$c_{1,i}$ - Coeficiente de variação inter-anual para a banda LANDSAT;

T_k^* - Pontos de interrupção “KTH”;

$\rho(i, x)_{OLS}$ - Valor previsto para a banda LANDSAT na data Juliana “X”.

As figuras expressam as curvas espectrais de alvos na banda 5 do satélite LANDSAT representadas pela superfície de reflectância em seis datas diferentes de uma série temporal.

FIGURA 2 - TRÊS CATEGORIAS DE MUDANÇA NA SUPERFÍCIE TERRESTRE MOSTRADOS NA BANDA 5 ATRAVÉS DA REFLECTÂNCIA DE SUPERFÍCIE: (1) MUDANÇA INTRA-ANUAL (OU SAZONALIDADE) (FIG. A); (2) MUDANÇA INTER-ANUAL (OU TENDÊNCIA) (FIG. B); E (3) MUDANÇA ABRUPTA (OU PAUSA) (FIG. C)



FONTE: Zhu e Woodcock (2014).


Com base em estudos anteriores, Zhu e Woodcock (2014), descrevem que a mudança identificada em três datas sucessivas foi a que apresentou os melhores resultados. Portanto, pixels que mostram a mudança para uma ou duas vezes consecutivas será sinalizado como "possível mudança" e se uma terceira mudança consecutiva é encontrada, o pixel é atribuído à classe "mudança". Para detectar um tipo de mudança de cobertura do uso do solo, por exemplo, alterações em floresta, um só índice de mudança com um limite fixo é suficiente. Entretanto para encontrar vários tipos de mudanças de cobertura do uso do solo, é preciso usar mais de uma banda espectral simultaneamente. Além disso, o limite para a mudança pode definir também a distinção para diferentes tipos de mudanças de cobertura do uso do solo. Portanto, o algoritmo CCDC usa todas as bandas espectrais do satélite LANDSAT

uma data referência com um limiar (ajustado para cada pixel individual) visando detectar diversas mudanças nos tipos de cobertura do solo.

Segundo os autores, o método OLS (Equação 14) é aplicado a todas as sete bandas do LANDSAT e por meio do erro quadrático médio são calculadas a diferença normalizada entre as observações e as previsões do modelo. São usadas três vezes o erro quadrático médio, devido ao fato dos sinais espectrais normalmente desviarem do modelo de previsão quando a alteração da cobertura de uso do solo ocorre.

O princípio básico da classificação do uso do solo é que diferentes classes de cobertura terão formas diferentes para a série temporal estimada no modelo. A FIGURA 3 ilustra os modelos de série temporal estimado para dois tipos diferentes de mudanças (floresta e agricultura) que ocorreram na área de estudo.

FIGURA 3 - EXEMPLOS DOS MODELOS ESTIMADOS DE SÉRIES TEMPORAIS PARA TODAS AS SETE BANDAS DO LANDSAT PARA DETECÇÃO DA COBERTURA COMPARANDO FLORESTA E AGRICULTURA



FONTE: Zhu e Woodcock (2014).

2.4 LIMIAZIZAÇÃO DE IMAGENS

Nos estudos de análise temporal por comparação de imagens, geralmente é derivada uma imagem contendo as supostas alterações ou diferenças entre as imagens. As diferenças pequenas não podem ser consideradas necessariamente alterações na cobertura da Terra. Elas podem decorrer de diferenças de iluminação ou até de pequenas variações no histograma das imagens. Por este motivo, a imagem de diferenças é analisada segundo a intensidade do valor da diferença, sendo binarizada em duas classes, “alteração” e “não alteração”, usando um limiar.

O limiar pode ser determinado pelo usuário, analisando o histograma da imagem de diferença e escolhendo o valor mais apropriado, geralmente detectando

um vale no histograma que separa valores altos (mudança) de valores baixos (não mudança). Este Limiar também pode ser obtido automaticamente, o que simplifica o trabalho, aplicando um método de limiarização automático. Neste trabalho, o Método de Otsu foi selecionado e é descrito a seguir.

De acordo com Marques Filho e Vieira Neto (1999), a limiarização consiste na separação em duas classes (fundo e objeto), partindo de uma imagem ou parte da mesma, produzindo uma imagem binária de saída (binarização). Para executar a limiarização, o método mais comum é aquele que faz a bipartição do histograma, que irá converter os pixels onde o nível de cinza será maior ou igual a um valor de limiar determinado.

2.4.1 Método Otsu

De acordo com Otsu (1979), esse é um método automático não paramétrico e não supervisionado de seleção de um limiar ótimo que permite separar uma imagem em duas classes, tendo como principais vantagens sua simplicidade e podendo ser empregado em histogramas unimodais, bimodais ou multimodais, abrangendo um vasto leque de aplicações sem supervisão no processo de decisão.

De acordo com Lopes (2003), esse método baseia-se na análise discriminante. A operação de limiarização é considerada como sendo o particionamento dos pixels de uma imagem com “I” níveis de cinza. Conforme Sahoo et al. (1988), um limiar ótimo pode ser calculado através da maximização de uma das seguintes funções critérios (Equações 15, 16 e 17):

$$\varphi = \frac{\sigma_B^2}{\sigma_w^2} \quad (15)$$

$$\eta = \frac{\sigma_B^2}{\sigma_t^2} \quad (16)$$

$$K = \frac{\sigma_t^2}{\sigma_w^2} \quad (17)$$

Onde:

σ_w^2 Variância dentro da classe;

σ_B^2 Variância entre as classes;

σ_t^2 Variância total.

Das três funções critérios acima, η é a mais simples, logo, o limiar ótimo pode ser obtido encontrando o valor “t” que maximiza a função η .

Onde:

$$\sigma_t^2 = \sum_{i=0}^{G-1} (i - \mu_t)^2 p_i$$

$$\mu_t = \sum_{i=0}^{l-1} i P_i$$

$$\sigma_B^2 = \omega_0 \omega_1 (\mu_1 \mu_0)^2$$

$$\bar{\omega}_0 = \sum_{i=0}^t P_i$$

$$\bar{\omega}_1 = 1 - \bar{\omega}_0$$

$$\mu_1 = \frac{\mu_T - \mu_i}{1 - \mu_0}$$

$$\mu_0 = \frac{\mu_i}{\bar{\omega}_0}$$

$$\mu_i = \sum_{i=0}^t i P_i$$

$$P_i = \frac{n_i}{n}$$

Onde n_i é o número de pixels com nível de cinza i e “ n ” é o número total de pixels de uma dada imagem definida como:

$$n = \sum_{i=0}^{l-1} n_i$$

Também pode-se dizer que P_i é a probabilidade da ocorrência do nível de cinza i .

O método de Otsu como proposto disponibiliza meios para se analisar outros aspectos além da seleção de um limiar ótimo para uma dada imagem. Para a seleção do limiar t de uma dada imagem, a classe de probabilidades ω_0 e ω_1 indicam as porções das áreas ocupadas pelas classes C_0 e C_1 . As médias de classes μ_0 e μ_1 servem como estimativa dos níveis médios das classes na imagem original em níveis de cinza. Além disso, o valor máximo de η , denotado por η_{\max} , pode ser utilizado como medida de separação das classes C_0 e C_1 na imagem original ou na bimodalidade do histograma.

2.5 MONITORAMENTO TEMPORAL DE ÁREAS AGRÍCOLAS


Em áreas agrícolas os principais alvos encontrados são: vegetação, solos e água. Por este motivo faz-se a seguir uma breve apresentação das características espectrais destes alvos.

2.5.1 Vegetação

A reflectância na vegetação varia em função de cada espécie vegetal, do estágio fenológico, dos aspectos sanitários e de condições adversas do clima, tendo a seca como a mais importante em nosso ambiente. De acordo com Moreira (2000), geralmente a vegetação verde sadia apresenta um comportamento muito próximo do padrão de resposta de suas folhas.

O processo de reflexão da radiação eletromagnética em uma folha verde sadia pode ser representado por uma curva chamada “Curva do Fator de Reflectância Direcional-Hemisférica”. De acordo com Ponzoni e Shimabukuro (2009) essa curva é influenciada pelo teor de umidade nas folhas para cada espécie vegetal. A curva de reflectância característica de uma folha verde sadia é mostrada na FIGURA 4.

FIGURA 4 - CURVA DE REFLECTÂNCIA TÍPICA DE UMA FOLHA VERDE.



FONTE: Novo (1989).

Na região do infravermelho próximo, valores altos de reflectância são observados para a vegetação sadia. Conforme Ponzoni e Shimabukuro (2009), esses valores são maiores ainda quando se observa a vegetação em uma imagem de satélite, devido ao efeito das camadas múltiplas. No infravermelho próximo pode-se verificar que parte da porção de radiação eletromagnética que atravessa integralmente a camada superior de folhas, ao atingir a segunda camada, pode ser refletida e em direção ao sensor, aumentando assim o total de energia vista desde o espaço.

2.5.2 Solo

De acordo com Baumgardner et al. (1986) a característica da radiação eletromagnética refletida por um determinado solo depende da natureza de sua


superfície, da intensidade e da qualidade espectral da radiação incidente sobre o mesmo. A superfície do solo pode ser refletida pela incidência da luz solar direta, dos poros, além da radiação térmica proveniente do entorno.

Chuvieco (1990) descreve que o solo apresenta um comportamento espectral uniforme nas regiões do visível e infravermelho próximo, com uma curva espectral plana e ascendente diferente do que ocorre com a vegetação. O mesmo autor destaca que a estrutura superficial do solo interfere na resposta espectral devido às variações inerentes ao conteúdo de umidade e sombreamento e que os principais fatores que afetam o comportamento espectral do solo são: textura, estrutura e composição química, nesse caso sendo primordial o teor de matéria orgânica.

A composição do solo origina mudanças espectrais, devido aos materiais presentes no mesmo. Por exemplo, o aumento do teor de matéria orgânica diminui a reflectância, sendo que acima de 2% de matéria orgânica há um mascaramento de outras propriedades espectrais dos solos. O melhor nível de matéria orgânica é discriminado no visível e no infravermelho próximo até 1,2 μm . Os minerais interferem na granulometria e na coloração.

De acordo com Moreira (2000), tem-se como propriedades intrínsecas do solo: a textura, a mineralogia, a presença de óxidos de ferro e o conteúdo de matéria orgânica. Dessas propriedades, a textura é aquela com maior ligação com a reflectância, pois está muito relacionada com a umidade. Os solos de textura arenosa sendo bem drenados (menor retenção de água) possuem reflectância mais alta. Os solos mal drenados de textura argilosa geralmente apresentam reflectância menor.

FIGURA 5 – CURVAS ESPECTRAIS DE ALGUNS TIPOS DE SOLOS.



FONTE: Demattê et al. (2005).

2.5.3 Água

Outro componente presente na atividade agrícola é a água. No estado líquido e limpa, a absorção da radiação eletromagnética é máxima e a reflectância é baixa na faixa entre 380 nm e 700 nm. No estado gasoso, ocorre maior absorção nas faixas acima de 1.300 nm, enquanto no estado sólido a absorção se dá na faixa de 1.200 nm a 2500 nm. (NOVO, 2010).

2.6 ÍNDICES DE VEGETAÇÃO

Com base nas características espectrais dos alvos mais frequentes em cenas naturais de áreas agrícolas, fica evidente que a vegetação é caracterizada por alta reflectância no infravermelho próximo e baixa reflectância na região do visível. Isto permite discriminar a vegetação em relação aos outros alvos, como mostra a TABELA 1. Além disso, um fato marcante é que a vegetação sadia apresenta alta diferença de reflectância entre o vermelho e infravermelho. Esta diferença tende a cair quando a vegetação sofre algum tipo de estresse, pois a produção de clorofila diminui e o pico de absorção do vermelho decresce.

TABELA 1 - COMPARAÇÃO DA VARIAÇÃO ESPECTRAL DE ALVOS NAS REGIÕES DO VISÍVEL, INFRAVERMELHO PRÓXIMO E MÉDIO.

Faixa espectral	Visível	Infravermelho próximo	Infravermelho médio
Vegetação sadia	Baixa	Alta	Baixa / média
Solos	Baixa	Alta / Média	Baixa / média
Água	Baixa	Nula	Nula

FONTE: o autor (2017).

Este fato levou à proposta de índices espectrais que salientassem esta diferença, os índices de vegetação. Epiphany et al. (1996), define os índices de vegetação como transformações lineares entre bandas do espectro eletromagnético, especialmente o vermelho e infravermelho próximo devido a essas duas conter mais de 90% da resposta espectral da vegetação.

Os índices de vegetação são valores que permitem relacionar parâmetros biofísicos e características da vegetação, por exemplo, podendo estimar o Índice De Área Foliar (IAF), a biomassa vegetal, produtividade e atividade fotossintética (HUETE, 1988). Os valores obtidos pelo IAF, SAVI e NDVI estão diretamente ligados à disponibilidade de água no perfil do solo (LEDA et al. 2016). De acordo com Daughtry et al. (1984), pode-se afirmar que o NDVI e o IAF são altamente correlacionados quando comparadas variáveis biofísicas e características espectrais entre as culturas de algodão e soja.

De acordo com Moreira (2000), a combinação de duas ou mais bandas espectrais, quando usada para analisar a vegetação, melhora a interpretação dos dados, por meio do uso de valores espectrais como: voltagem de saída do sensor, radiância, nível de cinza e reflectância. O mesmo autor cita (Jackson e Huete, 1991; Huete, 1996) ressaltando que a importância para caracterizar um índice de vegetação é que o mesmo possa ser usado sem restrição a determinada região (espaço) ou período (tempo), podendo responder a pequenas variações no estado fenológico da vegetação, além de não ser fortemente influenciado por variações nas condições e tipos de solo, na geometria de iluminação e visada e nas condições atmosféricas

De acordo com Portillo (2008), os índices de vegetação necessitam reconhecer os parâmetros biofísicos, sofrendo pouca influência do ângulo de inclinação solar, ângulo de visada e efeitos atmosféricos. O emprego dos índices de

vegetação pode fornecer dados da cena agrícola quanto ao desenvolvimento das culturas, porém não identificam a natureza das variações ocorridas ao longo do ciclo agrícola como é o caso da rotação de culturas.

Com relação à influência da atmosfera, o espalhamento atmosférico aumenta do infravermelho próximo para o visível quanto à contribuição aditiva, tendo ação contrária com o efeito subtrativo da absorção atmosférica maior para a faixa do infravermelho próximo. Os elementos que mais afetam no cálculo dos índices de vegetação na faixa de 600 a 1100 nm são o oxigênio (O₂) próximo de 760 nm e da água sob vapor (H₂O) em torno de 940 nm (GAO et al. 1993).

2.6.1 Índice de Vegetação da razão simples (*Simple Ratio* - SR)

De acordo com Ponzoni e Shimabukuro (2009), esse índice foi o primeiro a ser usado. É calculado pela razão entre os valores da região do infravermelho próximo pelos valores da região do vermelho, segundo a Equação 17 descrita abaixo.

$$SR = \rho_{IVP} / \rho_V \quad (17)$$

Onde:

ρ_{IVP} – reflectância na banda do infravermelho próximo;

ρ_V – reflectância na banda do vermelho.

A grande desvantagem desse índice é que em regiões com alta densidade de vegetação, os valores de radiação eletromagnética refletida referente à região do vermelho se aproximam de valores muito pequenos aumentando sem limites o valor final desse índice.

2.6.2 Índice de Vegetação por Diferença Normalizada (NDVI)

É considerado o índice de vegetação mais conhecido e utilizado. Rouse et al. (1973) descrevem o NDVI (*Normalized Difference Vegetation Index*) como sendo a razão entre a diferença da medida da reflectância nas bandas do infravermelho próximo e vermelho e a soma desses canais (Equação 18), sendo que o valor obtido pode variar de -1 a +1.

$$NDVI = (\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V) \quad (18)$$

Onde:

ρ_{IVP} - reflectância na banda do infravermelho próximo;

ρ_V - reflectância na banda do vermelho.

De acordo com Rosendo (2005), os valores de NDVI próximos de 1, representam uma vegetação mais densa e vigorosa enquanto para valores iguais ou próximos de zero (0), indicam superfícies não vegetadas ou com vegetação estressada.

Ponzoni e Shimabukuro (2009), descrevem que o NDVI permite comparações inter-anuais ou medir a sazonalidade de uma determinada espécie vegetal através da análise da fenologia, estágio de crescimento, pico vegetativo, alterações fisiológicas nas folhas e senescência.

Para Jensen (2005) a importância desse índice além das comparações da sazonalidade da vegetação, é que o mesmo possibilita a redução de ruídos presentes nas imagens, tais como: sombras de nuvens, variações topográficas e diferença de iluminação solar.

O método NDVI apresenta como vantagens: a facilidade de cálculo e a grande aceitação em estudos anteriores, o que estabelece o mesmo como um padrão para estudos de uso do solo, seja para imagens de baixa ou média resolução espacial (CIHLAR, 2000)

Uma vegetação sadia, em pleno crescimento ativo, com elevado vigor, tem baixa refletância na faixa do vermelho e alta refletância no infravermelho próximo apresentando um alto valor de NDVI.

De acordo com Thenkabail et al. (2000), através do uso do NDVI é possível caracterizar as variáveis biofísicas agrícolas, especialmente a biomassa e o índice de área foliar (IAF). Wang et al. (2005) demonstram que quando o IAF atinge um pico máximo, há uma queda na correlação entre esse índice e o NDVI devido à saturação do último. O intervalo dinâmico do NDVI é ampliado sob condições de biomassa em baixos níveis, sendo comprimido em condições de alta biomassa especialmente em áreas de florestas.

2.6.3 Índice de Vegetação Ajustado para o Solo (SAVI)

De acordo com Huete (1988), o brilho refletido pelo solo influencia de forma significativa no cálculo dos índices de vegetação em função do espectro de radiação proveniente de dosséis vegetais esparsos, com 50% de cobertura verde em relação ao solo. Essa influência é maior principalmente em substratos de solos escuros, sendo um fator que propicia um aumento no valor de índices de vegetação como o NDVI. Para minimizar as influências do solo na caracterização do dossel das plantas, o autor desenvolveu o SAVI (*Soil-Adjusted Vegetation Index*). Dessa forma, introduz-se uma constante “L” que tem a função de minimizar o efeito do solo no resultado final do índice, sendo estimada a partir de medições experimentais da refletância, calculada para as bandas do infravermelho próximo e do vermelho na cultura do algodão e da pastagem. A Equação 19 expressa o cálculo do SAVI.

$$SAVI = (1+L) * (\rho_{IVP} - \rho_V) / (\rho_{IVP} + \rho_V + L) \quad (19)$$

Onde:

ρ_{IVP} - refletância na banda do infravermelho próximo;

ρ_V - refletância na banda do vermelho;

L - constante que minimiza o efeito do solo, que pode variar de 0 a 1 (TABELA 2).

TABELA 2 - VALORES ÓTIMOS DA CONSTANTE “L” EM FUNÇÃO DA DENSIDADE DE VEGETAÇÃO

Densidade de vegetação na superfície	Valor da constante “L”
Baixa	1
Média	0,5
Alta	0,25

FONTE: Huete (1988).

2.6.4 Índice de Vegetação Realçado (EVI)

De acordo com Risso et al. (2012), o EVI foi proposto a partir da combinação de outros dois índices de vegetação: o Índice de Vegetação Ajustado Para o Solo (SAVI) e o Índice de Vegetação Resistente à Atmosfera (ARVI).

Esse índice apresenta uma melhor sensibilidade para monitoramento em áreas com elevada quantidade de biomassa e maior vegetação permitindo uma dissociação do dossel em relação ao sinal de fundo, além de uma redução na influência atmosférica (SILVEIRA et al., 2008). O EVI é calculado pela Equação 20.

$$EVI = G [(\rho_{IVP} - \rho_v) / (\rho_{IVP} + c_1 \times \rho_v - c_2 \times A + L)] \quad (20)$$

Onde:

ρ_{IVP} , ρ_v e A são os fatores de reflectância bidirecionais de superfície nas bandas do infravermelho próximo, do vermelho e do azul, respectivamente;

G é o fator de ganho que corresponde a 2,5;

C_1 é o coeficiente de correção dos efeitos atmosféricos para a banda do vermelho com valor de 6;

C_2 é o coeficiente de correção dos efeitos atmosféricos para a banda do azul cujo valor é igual a 7,5;

L é o fator de correção para a interferência do solo, igual a 1.

De acordo com Risso et. al. (2012) os coeficientes C_1 e C_2 podem ser alterados de acordo com as condições regionais.

2.6.5 Índice de Área Foliar (IAF)

O Índice de Área Foliar (IAF) é um índice biofísico definido pela razão entre a área foliar total de uma vegetação por unidade de área associada ao solo utilizada por esta vegetação (ALLEN et al., 2002).

De acordo com Leda et al. (2016), o IAF é um subproduto do NDVI e SAVI, sendo que o mesmo apresenta valores menores no período seco e valores maiores no período úmido. Quando o IAF é utilizado em conjunto com o SAVI, é possível obter a modelagem de parâmetros biofísicos das plantas, como a área foliar, biomassa e porcentagem de cobertura do solo (EPIPHANIO et al., 1996).

Abaixo temos a Equação 22 que descreve o IAF.

$$IAF = - \frac{\ln\left(\frac{0,69-SAVI}{0,59}\right)}{0,91} \quad (22)$$

De acordo com Leda et al. (2016), a relação entre o SAVI e o IAF pode variar com a localização e tipo de cultura. O valor máximo para o IAF é 6 (seis), que equivale a um SAVI máximo de 0,687, que se passado desse valor ocorre a “saturação” do SAVI não havendo mais alteração significativa nos valores.

3. ÁREA DE ESTUDO

A área de estudo compreende três propriedades rurais do Grupo JPupin localizadas no município de Campo Verde-MT. As mesmas estão divididas em: Fazenda Marabá, Fazenda Manacá e Fazenda Eldorado (as duas últimas são áreas contíguas). As coordenadas e altitude na sede de cada fazenda estão descritas na TABELA 3.

TABELA 3 - COORDENADAS UTM E ALTITUDE MÉDIA NAS SEDES DAS PROPRIEDADES ESTUDADAS

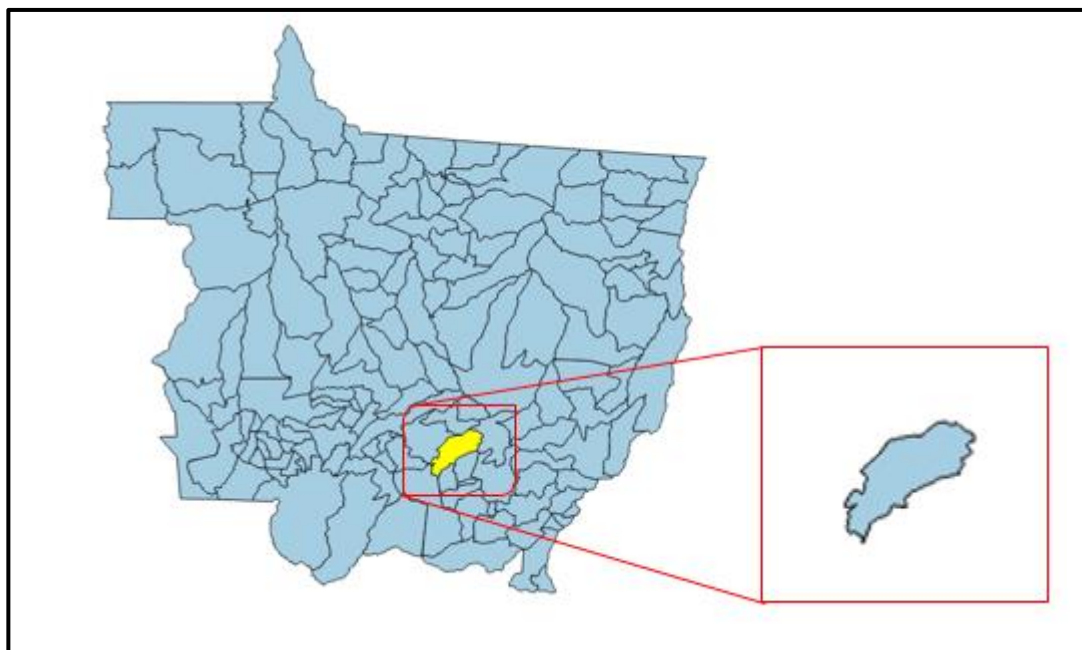
Propriedade	Coordenadas UTM da sede	Altitude na sede (m)
Faz. Marabá	E 701257,5 m	672
	N 8310646,2 m	
Faz. Manacá	E 709927,1 m	743
	N 8326471,6 m	

FONTE: Grupo JPUPIN (2016).

O município de Campo Verde pertence à microrregião de Primavera do Leste e da mesorregião Sudeste do Mato Grosso (FIGURA 6). A área total do município é de 4.782 km², com população estimada em 38.814 habitantes (IBGE, 2016).

As duas culturas estudadas foram algodão e soja. No caso do algodão, o município se destaca na produção dessa cultura em nível nacional sendo que os dados segundo o IBGE (2016), para a safra do ano de 2015 correspondem à produção de 337 mil toneladas (algodão em caroço), tendo uma área plantada de 81.996 hectares e produtividade média de 4.110 kg/ha, ou seja, muito maior que a média do estado e correspondendo ao município aproximadamente 15% da produção do estado de Mato Grosso. De acordo com a Prefeitura Municipal de Campo Verde, a produção de soja para a safra 2015/2016 foi de 594 mil toneladas, com uma área plantada de aproximadamente 180 mil hectares e produtividade média de 3.300 kg/ha.

FIGURA 6 - LOCALIZAÇÃO DO MUNICÍPIO DE CAMPO VERDE NO ESTADO DE MATO GROSSO.



FONTE: O autor (2017).

O clima do município é do tipo Aw – Tropical de Savana, segundo a classificação climática de Koeppen. O mesmo apresenta uma estação chuvosa no verão, de novembro a abril, e nítida estação seca no inverno, de maio a outubro (julho é o mês mais seco). A temperatura média do mês mais frio é superior a 18°C. As precipitações são superiores a 750 mm anuais, atingindo até 1800 mm. Na TABELA 4 são apresentadas as médias de precipitação em mm de cada mês nos anos de 2013 a 2015, período do estudo, além da média de precipitação acumulada para cada ano. Como as demais áreas, fazenda Manacá e Eldorado estão próximas (20km), podemos adotar esses valores como referência para as mesmas.

Os solos na área de estudo apresentam grande variação. As principais classes são: Latossolo Vermelho Distrófico típico de textura argilosa (LVd), Latossolo Vermelho-Amarelo Distrófico típico de textura média (LVAd) e Neossolo Quartzarênico Órtico típico de textura arenosa (RQo).

A principal característica agronômica dos Latossolos é sua grande profundidade e boa drenagem interna sendo que a espessura do solum é raramente inferior a um metro. A seqüência de horizontes A, B, C, apresenta pouca diferenciação de sub-horizontes com transições usualmente difusas ou graduais entre os mesmos. Essa condição de profundidade facilita a agricultura mecanizada, pois são solos

altamente intemperizados que não possuem minerais primários ou secundários menos resistentes ao intemperismo e tem como característica importante a acidez com baixa saturação por bases. A coloração varia do matiz 2,5YR ou mais vermelho na maior parte dos primeiros 100cm para os Latossolos Vermelhos (LV), enquanto para os Latossolos Vermelho-amarelo temos o matiz 2,5YR a 7,5YR na maior parte dos primeiros 100cm (LVA). Essa característica permite fazer a distinção visual das duas classes, bem como é sensível ao sensor.

TABELA 4 - RELATÓRIO MENSAL PLUVIOMÉTRICO DA FAZENDA MARABÁ PARA OS ANOS DE 2013 A 2015.

Dados pluviométricos da Fazenda Marabá (mm)			
Mês	Média ano 2013	Média ano 2014	Média ano 2015
Janeiro	186,44	214,48	331,03
Fevereiro	210,17	212,27	213,06
Março	117,50	278,97	209,88
Abril	164,50	178,64	82,09
Maio	37,55	68,97	46,38
Junho	0,54	10,93	0,00
Julho	0,00	25,97	0,00
Agosto	0,00	0,00	47,19
Setembro	0,00	47,53	0,00
Outubro	131,94	106,03	74,60
Novembro	64,20	152,90	125,50
Dezembro	99,67	256,30	110,47
Acumulado	1066,51	1553,32	1341,29

FONTE: Grupo JPUPIN (2016).

O Neossolo Quartzarênico, antiga classe das Areias Quartzosas, são solos com alta susceptibilidade à erosão e usados na área para cultivo de soja sem rotação com algodão devido à baixa fertilidade natural. Outra finalidade dessa classe de solo é para cultivo de eucalipto.

De acordo com a SEPLAN (2001), através do Projeto de Desenvolvimento Agroambiental do Estado de Mato Grosso (PRODEAGRO) a área de estudo é descrita como:

- a) Presença de duas unidades microclimáticas associadas aos respectivos tipos de relevo, sendo os topos da Chapada dos Guimarães (o que é

visto pela altitude relativamente elevada) além do planalto do rio das Mortes;


- b) A vegetação nativa predominante é composta de savanas arborizadas (cerrado), seguida da savana florestada (cerradão) e pelas formações savânicas associadas às vertentes ou nascentes com matas de drenagem;
- c) A aptidão agrícola apresenta na maior porção da área de estudo composta por terras boas para lavouras de ciclo curto ou longo, tendo em segundo grau de importância terras com aptidões boas, regulares ou restritas para pastagem plantada e por último as terras com aptidão regular para lavouras de ciclo curto ou longo;
- d) Quanto às formações geológicas se destacam as superfícies paleogênicas peleplanizadas com latossolização, Formação Marília (arenitos de granulometria variada), e aluviões atuais (areias, siltes e argilas) em menor medida.

O Cerrado que é a vegetação nativa da região possui uma área total de 2,04 milhões de km², o que corresponde a cerca de 20% do território brasileiro e é considerada a savana mais rica do mundo em biodiversidade. De acordo com Klink e Machado (2005) pode ser considerada a última fronteira agrícola do planeta que está em franca destruição, sendo que 55% já foi desmatada.

3.1 FAZENDA MARABÁ

A propriedade compreende uma área total de 18.178,5848 hectares. A altitude na Fazenda Marabá varia em média de 660 a 770 metros. As culturas principais da área são o algodão (*Gossypium spp.*) e a soja (*Glycine max*). Na FIGURA 7 é possível ver a área total da propriedade e também a divisão dos talhões.

FIGURA 7 – ÁREA TOTAL DA FAZENDA MARABÁ COM A DIVISÃO DOS TALHÕES (EM AMARELO).



FONTE: o autor (2017).


3.2 CARACTERIZAÇÃO DAS CULTURAS ESTUDADAS

3.2.1 Cultura do algodão

O algodão é uma planta da família *Malvaceae*, tendo como espécie mais cultivada no mundo (cerca de 90% do total) a *Gossypium hirsutum* L. que é a correspondente na área de estudo.

O algodoeiro segundo Marur e Ruano (2004), é uma planta de crescimento indeterminado que apresenta uma das mais complexas morfologias entre as plantas cultivadas e pode apresentar ciclos diversos. As variedades precoces têm seu ciclo produtivo em 130 dias, enquanto as variedades tardias podem ter mais de 170 dias. As fases ou estádios de crescimento e desenvolvimento são divididas em: vegetativa (V), formação de botões florais (B), abertura da flor (F) e abertura do capulho (C). No período vegetativo, entre a emergência da plântula e até que a primeira folha verdadeira tenha o comprimento de 2,5 centímetros de nervura principal, o estágio será V0. A partir do limite anterior e até que a segunda folha verdadeira tenha a sua nervura principal com comprimento de 2,5 centímetros, o estágio será V1. Sucessivamente, aplicando o mesmo critério, a planta avançará para os estádios V2, V3, V4, V5, etc. Nesta fase, considera-se folha verdadeira expandida quando a nervura principal de seu limbo foliar for maior que 2,5 centímetros (FIGURA 8).

FIGURA 8 – ESTÁGIOS DE CRESCIMENTO DO ALGODOEIRO.



FONTE: Marur e Ruano (2004).

O clima é o principal fator que influencia a época de plantio que é feita em condições ótimas de disponibilidade de água no solo. A colheita deve se dar em período de seca, quando ocorre a redução no volume de precipitação o que facilita a operação mecânica da colheita e evita a perda da qualidade da fibra (EMBRAPA, 2004). De acordo com Rosolem (2001) o algodoeiro é uma planta suscetível às variações térmicas, onde as noites frias e temperaturas diurnas baixas afetam o crescimento, especialmente na produção de frutos. A faixa mais adequada de temperatura para o desenvolvimento da cultura do algodão está entre 18 e 30°C, tendo como limite mínimo inferior 14°C, faixa de temperatura que é indutora do crescimento, pois é necessário um acúmulo térmico expresso pelo grau dia (GD) ou unidade de calor acumulada (UC), podendo ser calculada por:

$$UC = \Sigma [(T + t)/2 - 15] \quad (23)$$

Onde:

T: é a temperatura máxima diária;

t: é a temperatura mínima diária; e

15 é a temperatura base (°C).

Na FIGURA 9 pode-se ver como é a cultura do algodão na fase de pleno desenvolvimento vegetativo e no ponto de colheita.

FIGURA 9 - ASPECTO DA CULTURA DO ALGODÃO NA FASE VEGETATIVA E NO PONTO DE COLHEITA.



FONTE: EMBRAPA. (2016).

No município de Campo Verde o algodão é plantado com dois tipos de safras no mesmo ano agrícola. A primeira é conhecida como “algodão safra” com plantio em dezembro/janeiro e colheita em julho nos talhões com solo de maior fertilidade sem consórcio com a cultura da soja. A segunda é conhecida como “algodão safrinha” onde o plantio se dá no final de janeiro e início de fevereiro com a colheita no final de agosto e início de setembro, em talhões onde há sucessão à cultura de soja em áreas com média fertilidade do solo.

Na TABELA 5 é mostrado o ciclo médio de dias e unidade de calor para o desenvolvimento do algodão na região sudeste do estado de Mato Grosso considerando um experimento realizado por Rosolem (2001) no município de Rondonópolis (mesma região da área em estudo).

TABELA 5 – NÚMERO MÉDIO DE DIAS E UNIDADE DE CALOR (UC) QUE O ALGODÃO NECESSITA DURANTE SEU CRESCIMENTO EM VÁRIOS ESTÁDIOS.

Estádio de crescimento	Número de dias		Unidades de Calor (UC)	
	Mato Grosso	Literatura	Mato Grosso	Literatura
Semeadura à emergência		4-9		50-60
Emergência ao primeiro botão floral	33	27-38	358	425-475
Primeiro botão floral à primeira flor	21	20-25	271	300-350
Emergência à primeira flor	54	47-63	629	725-825
Primeira flor ao primeiro capulho	54	45-66	658	850
Emergência ao primeiro capulho	109	125-161	1287	1575-1675

FONTE: adaptado de Rosolem (2001).

3.3.2 Cultura da soja

A soja (*Glycine max* L.), é uma planta oleaginosa, onde aproximadamente 85% da colheita mundial é destinada à produção do óleo (consumo humano) e os resíduos da sua extração (torta e farelo) são usados na preparação de rações para animais, sendo que apenas 4% a 5% desses resíduos da extração do óleo são reprocessados em farinhas e proteínas para uso alimentício.

Conforme Farias et al. (2007), o ciclo fenológico da cultura da soja pode variar desde a germinação até a maturação completa de 75 a 200 dias. Essa variação ocorre devido a exigência de cada variedade além de seu fotoperíodo. Para o Mato Grosso, as cultivares recomendadas para a semeadura são: precoce/médio (133 a 142 dias), semitardio (145 dias) e tardio (145 a 150 dias).

Alvarez Filho (1988) descreve que o desenvolvimento da cultura da soja se divide em dois estádios ou fases de desenvolvimento: vegetativo (V) e reprodutivo (R). As subdivisões do estádio vegetativo são designadas numericamente como V1, V2, V3...Vn. Apenas os dois primeiros estádios são designados como VE (emergência) e VC (cotilédones). O último estádio vegetativo é designado como Vn, onde “n” representa o número do último nó vegetativo formado por um cultivar específico. O estádio reprodutivo apresenta oito subdivisões (R1 a R8) como pode ser visto. Na TABELA 6 são mostrados os estágios vegetativos e reprodutivos para a cultura da soja.

O plantio da cultura da soja em talhões onde há consórcio com algodão no mesmo ano agrícola (por exemplo, safra 2013/14) se dá no fim de setembro até primeira quinzena de outubro enquanto a colheita é feita no mês de janeiro do ano seguinte com solo de alta a média fertilidade. Para a soja sem rotação com algodão o plantio se dá no final de novembro e a colheita em abril, sendo usados os talhões de menor fertilidade da propriedade.

TABELA 6 – ESTÁGIOS VEGETATIVOS E REPRODUTIVOS DA SOJA.

Estágios vegetativos	Estágios reprodutivos
VE - Emergência	R1 – Início do florescimento
VC - Cotilédones	R2 – Pleno florescimento
V1 – Primeiro nó	R3 – Início da formação das vagens
V2 – Segundo nó	R4 – Plena formação das vagens
V3 – Terceiro nó	R5 – Início do enchimento dos grãos
*	R6 – Pleno enchimento dos grãos
*	R7 – Início da maturação
Vn – Enésimo nó	R8 – Maturação plena

FONTE: POTAFOS [s.d.]

Na FIGURA 10 pode-se ver como é a cultura da soja na fase de pleno desenvolvimento vegetativo e no ponto de colheita.

FIGURA 10 - ASPECTO DA CULTURA DA SOJA NO ESTÁGIO VEGETATIVO E NO PONTO DE COLHEITA



FONTE: EMBRAPA. (2016).

3.3.2 Rotação de culturas

De acordo com Derpsch et al. (1991), a rotação de culturas pode ser definida como uma sucessão ordenada de diferentes culturas num espaço de tempo, na mesma gleba, desde que uma mesma cultura não seja implantada no mesmo local por um período de pelo menos 2 anos.

Corrêa e Sharma (2004), avaliaram o efeito da rotação de culturas na produtividade do algodoeiro em plantio direto na região do Cerrado e verificaram que houve maior produção de pluma em sistema de rotação, principalmente, quando as culturas associadas eram a soja e o milheto, que proporcionou o melhor controle de plantas daninhas.

Em um sistema de rotação de culturas com a soja, o algodoeiro é uma ótima alternativa pois, além de proporcionar boa lucratividade ao produtor, tem sua produtividade incrementada quando cultivado após a soja (COSTA et al., 1993).

4. MATERIAIS

4.1 IMAGENS LANDSAT

Foram analisadas imagens de 22 datas no total compreendendo os anos de 2013 a 2015, sendo seis datas provenientes do satélite LANDSAT 7 e dezesseis do satélite LANDSAT 8. Para cada ano foi montada uma série temporal com 8 imagens (maio a dezembro) previamente processadas. O período do ano escolhido se deu devido as melhores condições climáticas principalmente à menor cobertura de nuvens na área. O número de oito meses, é pela necessidade de poder combinar cada data com um valor 2^n onde “n” inicia com o valor 1 para maio e termina com valor 8 para dezembro que permite obter uma escala de pesos de 0 a 255.

Para melhor análise dos dados, foi necessário repetir a imagem do dia 13/09/2013 para o mês de outubro do ano de 2013 e na série do ano de 2014 foi repetida a imagem do dia 07/10/2014 no lugar da data de novembro devido à presença de nuvens nas duas cenas substituídas. Para o ano de 2015 não houve repetição de imagens.

As imagens foram adquiridas gratuitamente no catálogo de imagens do USGS (*United States Geological Survey*) e foi usado como sistema de referência o *datum* WGS-84, fuso 21.

Para o satélite LANDSAT 8 foram necessárias 16 imagens de datas diferentes tomando a órbita 226, ponto 70, sendo que em apenas uma data (14/06/2013) houve necessidade de se fazer o mosaico devido à diferença de posicionamento do satélite para aquela data usando assim o ponto 71. Para o satélite LANDSAT 7 usamos 12 imagens correspondentes à órbita 226, pontos 70 e 71 que após a confecção dos mosaicos para cada data foram recortadas gerando 6 imagens e usadas na análise da área, sendo uma repetida como exposto anteriormente.

As imagens dos dois satélites apresentam resolução espacial de 30 m, ou seja, 0,09 ha. As bandas usadas foram o vermelho (banda 3) e o infravermelho próximo (banda 4) para o cálculo dos índices de vegetação NDVI e SAVI.

Cada imagem recebeu uma codificação numérica com seis valores (TABELA 7) onde é colocado o ano, mês e dia respectivamente. Como exemplo cita-se a imagem (150908), que corresponde na aquisição ao ano de 2015 (15), mês de

setembro (09) e dia 08. Dessa forma é possível identificar as imagens em uma escala temporal de fácil leitura.

TABELA 7 - CÓDIGO DAS IMAGENS USADAS EM FUNÇÃO DA DATA DE AQUISIÇÃO DAS MESMAS E SENSOR.

Código da Imagem	Data	Satélite
130505	05/05/2013	L7
130614	14/06/2013	L8
130716	16/07/2013	L8
130817	17/08/2013	L8
130926	26/09/2013	L7
131113	13/11/2013	L7
131223	23/12/2013	L8
140516	16/05/2014	L7
140609	09/06/2014	L8
140703	03/07/2014	L8
140820	20/08/2014	L8
140905	05/09/2014	L8
141007	07/10/2014	L8
141226	26/12/2014	L8
150527	27/05/2015	L7
150620	20/06/2015	L8
150730	30/07/2015	L7
150807	07/08/2015	L8
150908	08/09/2015	L8
151026	26/10/2015	L8
151111	11/11/2015	L8
151213	13/12/2015	L8

FONTE: o autor (2016).

4.2 SOFTWARES USADOS PARA O PROCESSAMENTO DAS IMAGENS

1) ENVI 4.5, software específico para processamento de imagens orbitais que compreende um conjunto amplo de ferramentas que proporciona inclusive o estudo de dados originados em áreas agrícolas permitindo a análise da qualidade do cultivo além de previsão de safras. O mesmo foi usado para:

- a) Efetuar o georreferenciamento da primeira imagem que serviu de referência para o registro das demais;
- b) Executar o registro para cada imagem nas diversas datas em relação à imagem de referência;
- c) Fazer a checagem da qualidade do produto final na correção geométrica automatizada através do erro quadrático médio (RMSE) nos pontos de controle;
- d) Recortar as imagens por meio das coordenadas UTM;

- e) Leitura dos valores digitais para os alvos seja em nível digital (ND) ou em reflectância;
- f) Composição de imagens com a combinação de bandas que permite a interpretação visual para análise em diferentes aspectos;

2) MATLAB®, abreviatura de *MATrix LABoratory*, é um *software* de alta performance desenvolvido para uso em cálculos numéricos especialmente de matrizes e desenvolvimento de gráficos, sendo usado nesse trabalho para:

- a) Geração das imagens dos índices de vegetação empregados no trabalho, (NDVI e SAVI);
- b) Binarização das imagens por limiarização automática pelo Método de Otsu;
- c) Correção das linhas perdidas nas imagens LANDSAT 7;
- d) Processamento de cada série anual (8 imagens) por meio de um algoritmo usando os valores binários combinado com um peso em cada imagem;
- e) Geração das imagens codificadas das séries temporais partindo das imagens pré-classificadas.

3) QGIS que consiste em um Sistema de Informação Geográfica (SIG) amigável, sendo um software livre licenciado sob a GNU, que significa, “*General Public License*”. O QGIS é um projeto oficial da *Open Source Geospatial Foundation* (OSGeo). Tem como características suportar vários formatos vetoriais, *raster*, de banco de dados e outras funcionalidades. O QGIS fornece um número crescente de aplicações através de suas principais funções e complementos. É possível visualizar, gerenciar, editar, analisar os dados e compor mapas impressos por exemplo. Fonte in: (<http://qgisbrasil.org>). Esse software foi usado nesse trabalho para a realização da correção atmosférica das imagens pelo método DOS (*Dark Object Subtract*).

4) MultiSpecW32. Consiste em um sistema de processamento para processamento de imagem multiespectral usado na série LANDSAT. O principal objetivo dessa ferramenta é analisar dados de imagens hiperespectrais. Também essa ferramenta foi empregada para:

- a) Fazer a classificação supervisionada das imagens multitemporais para o índice NDVI e SAVI pelo método da máxima verossimilhança (MaxVer);
- b) Fazer a pré-classificação não supervisionada (*clustering*) com o algoritmo ISODATA; para as imagens NDVI;
- c) Classificação pelo método da Mínima Distância Euclidiana dos *clusters* para definir o uso do solo em cada ano;
- d) Obter a estatística de classificação;

5. METODOLOGIA

Como Lu et al. (2003) apontam, estudos de detecção de alterações devem fornecer as seguintes informações:

- 1) Área de alteração e a taxa de mudança;
- 2) Distribuição espacial dos tipos alterados;
- 3) Tipos/natureza das alterações; e
- 4) Avaliação da precisão dos resultados da detecção de mudança.

A metodologia aqui apresentada também segue a orientação destes autores em linhas gerais, que são comuns a todos os estudos de detecção de alterações, porém apresenta diferenças quanto ao método específico. Ela compreende as seguintes etapas:

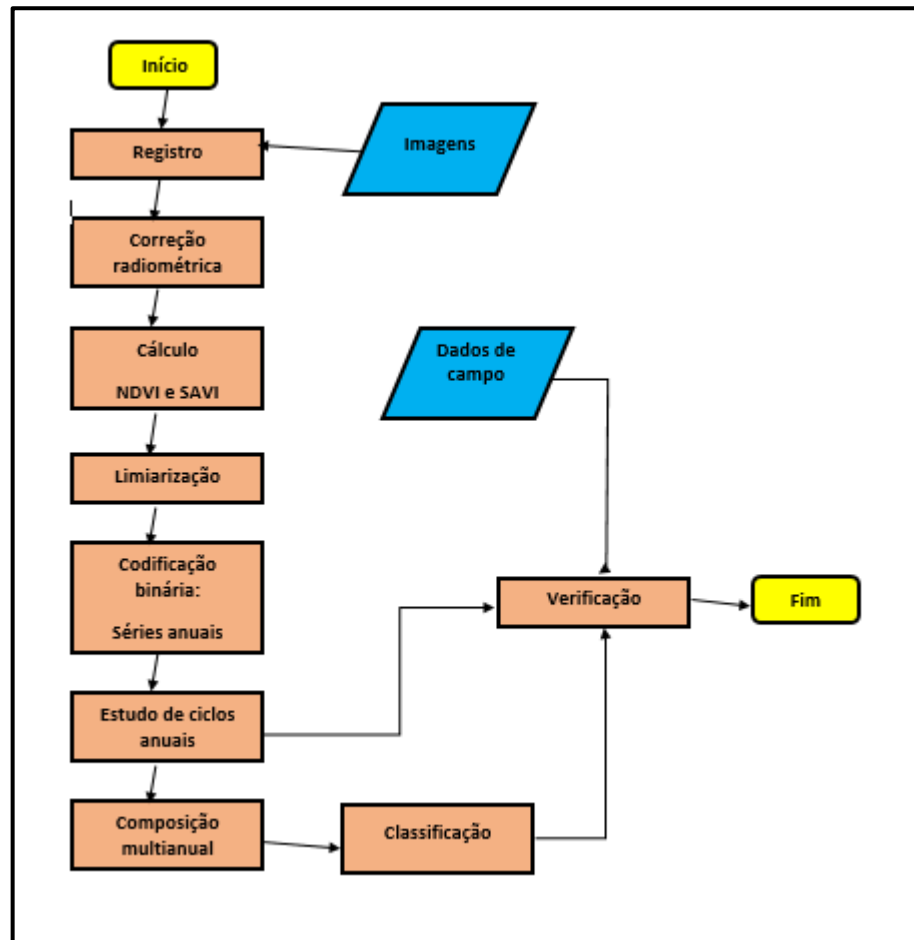
- 1) Pré-processamento, incluindo:
 - a) Correção geométrica e registro de imagens,
 - b) Correção radiométrica e atmosférica;
- 2) Análise de detecção de mudança.

A seguir serão detalhadas as etapas desta metodologia, que para sua melhor compreensão, é resumida na FIGURA 11 sob forma de um fluxograma das etapas realizadas.

O método proposto consiste em analisar em uma série multitemporal de imagens de satélite LANDSAT compreendendo 3 anos com dados mensais, ou seja, uma imagem por mês. Como em alguns meses não foi possível obter a imagem por excessiva cobertura de nuvens, oito imagens por ano foram usadas. Os meses selecionados cobrem os ciclos de alvos específicos nas áreas agrícolas de estudo: algodão e soja, bem como vegetação nativa (mata ciliar e cerrado) e eucalipto.

De posse das informações, será feita a análise da variação entre as culturas nos talhões, identificando seu ciclo. Dessa forma será possível verificar se há rotação ou não, bem como prever qual o ciclo existente.

FIGURA 11 - FLUXOGRAMA DAS ETAPAS DESENVOLVIDAS AO LONGO DO TRABALHO



FONTE: o autor (2017).

5.1 PRÉ-PROCESSAMENTO DAS IMAGENS

5.1.1 Recorte das imagens

Um recorte de cada imagem obtido delimitando a área comum de estudo em todas as datas. A área de estudo está compreendida entre as seguintes coordenadas: 694.455 E; 8.334.445 S para o canto superior esquerdo e 716.745 E; 8.297.575 S para o canto inferior direito.


Após o recorte, as imagens ficaram com a dimensão de 745 colunas por 1.230 linhas em pixel.

5.1.2 Preenchimento de linhas perdidas nas imagens LANDSAT 7

As imagens LANDSAT 7 em sua totalidade foram recebidas com uma falha sistemática onde havia linhas perdidas com pixel escuro, ou seja, nível de cinza (NC) igual a zero. Este erro é proveniente do mau funcionamento do sistema de compensação de movimento a bordo do LANDSAT 7, o SLC, sendo a informação perdida de forma permanente. Embora parte da imagem ainda seja válida para analisar a superfície da Terra, os pixels perdidos não fornecem nenhuma informação. Para poder usar estas imagens é necessário efetuar uma correção de forma artificial, preenchendo estas falhas. O autor apresenta como uma solução adequada para a estimativa dos valores dos números digitais utilizando os pixels vizinhos, pois os mesmos apresentam alta correlação espacial.


Desta maneira foi necessário preencher essas linhas por meio de um algoritmo desenvolvido no MATLAB. Esse algoritmo preenche os valores vazios onde o nível de cinza (NC) é igual a zero nas linhas perdidas através da substituição do valor da última linha sem falha para todas as vazias até a próxima linha com valor válido. Dessa forma é possível deixar a imagem com o histograma mais próximo do real, não causando distorções demasiadas. As imagens antes e após o uso do algoritmo podem ser observadas na FIGURA 12. O mesmo pode-se observar para os histogramas das mesmas imagens na FIGURA 13.

FIGURA 12 - IMAGEM LANDSAT 7 DA ÁREA DE ESTUDO NA DATA DE 30/07/2015 NA BANDA 4 COM AS LINHAS PERDIDAS (A) E APÓS CORREÇÃO DAS LINHAS PERDIDAS (B)



FONTE: o autor (2017).

FIGURA 13 - HISTOGRAMAS DAS IMAGENS LANDSAT 7 NA DATA DE 30/07/2015 SENDO (A) PARA AQUELA COM AS LINHAS PERDIDAS E (B) APÓS CORREÇÃO DAS LINHAS PERDIDAS



FONTE: o autor (2017).

5.1.3 Correção geométrica

No presente trabalho foi usado o modelo polinomial de primeiro grau para correção geométrica, com pontos de controle bem distribuídos na imagem. O valor

máximo do RMS aceito para o registro foi de 0,4 pixel. Após o ajuste, foi feito o cálculo dos novos valores digitais, utilizando o Método da Convolução Cúbica para reamostragem.

Os pontos de controle foram identificados no terreno a partir de uma imagem de referência (150908), do dia 08 de setembro de 2015, cujas coordenadas são conhecidas na imagem e no sistema de referência sendo adotado o *datum* WGS-84.

5.1.4 Correção atmosférica

A correção atmosférica tem como finalidade reduzir a parcela aditiva nas leituras dos valores digitais, causada pelo espalhamento atmosférico (Chavez Jr., 1996). O espalhamento é seletivo e afeta principalmente as bandas com menores comprimentos de onda. No caso do sistema LANDSAT, os comprimentos de onda do visível são os mais afetados. Como este é um estudo multitemporal, é necessário levar em consideração os efeitos do espalhamento, que podem variar ao longo do ano e de ano para ano.

Para reduzir o efeito do espalhamento foi usado o método do pixel mais escuro (*Dark Object Subtraction* – DOS), proposto por Chavez Jr. (1996). De acordo com Chavez Jr. (1988) os valores mínimos encontrados em cada banda da imagem não devem ser subtraídos porque tende a haver uma superestimação na correção das outras bandas. Dessa forma deve ser feito o cálculo do espalhamento em cada banda individualmente, partindo apenas do valor de ND de frequência mais baixa encontrado na banda de menor comprimento de onda escolhido no histograma de forma subjetiva. Esse valor permite identificar a condição atmosférica no momento da obtenção da imagem, gerando um expoente para o modelo de espalhamento relativo.

5.2 CÁLCULO DOS ÍNDICES DE VEGETAÇÃO

Para o cálculo dos índices de vegetação foram empregadas todas as imagens na sequência temporal iniciando no mês de maio a terminando em dezembro para cada ano (2013 a 2015). Os meses de janeiro a abril foram suprimidos devido à alta cobertura de nuvens nessa época do ano para a região.

5.2.1 Cálculo do índice de vegetação por diferença normalizada (NDVI)

Para o cálculo do NDVI, os procedimentos desenvolvidos nessa etapa do trabalho foram:

- a) Cálculo do NDVI utilizando as bandas do vermelho e infravermelho próximo para cada uma das imagens nas datas diferentes utilizando o MATLAB, onde se aplicou a Equação 18, descrita no item 2.6.2 desse trabalho;
- b) Multiplicação do resultado obtido na etapa anterior pelo valor 127,5, além da soma de 127,5 para expressar o ND na escala de 8 bits (0 a 255), pois de acordo com Rouse et al. (1973), os valores de NDVI variam de -1 a 1, que corresponde respectivamente ao comportamento da água até a vegetação exuberante;

5.2.2 Cálculo do índice de Vegetação Ajustado para o Solo (SAVI)

A sequência de imagens empregadas foi idêntica ao do NDVI permitindo uma comparação equivalente. Os procedimentos desenvolvidos nessa etapa do trabalho foram:

- a) Cálculo do SAVI utilizando as bandas do vermelho e infravermelho próximo para cada uma das imagens nas datas diferentes utilizando o MATLAB, onde se aplicou a Equação 19, descrita no item 2.6.3 desse trabalho;
- b) O fator de correção (L) usado variou de acordo com a época do ano em função da cobertura vegetal nas áreas de agricultura em contraste com as áreas com solo exposto. Os valores usados nesse trabalho são apresentados na TABELA 8.

TABELA 8. VALOR DA CONSTANTE "L" USADA NO CÁLCULO DO SAVI EM FUNÇÃO DA DENSIDADE DE VEGETAÇÃO.

Meses	Valor de "L"	Cobertura vegetal (Área agrícola)
Maio a julho	0,5	Média
Agosto e setembro	1,0	Baixa
Novembro e dezembro	0,25	Alta

FONTE: o autor (2017).

As imagens geradas após o cálculo dos índices de vegetação (NDVI e SAVI) foram armazenadas em 8 bits, com 256 níveis digitais. Os valores altos são associados à vegetação e os valores baixos a outros alvos, como solo exposto e água.

5.3 SEGMENTAÇÃO DE VEGETAÇÃO

Os valores dos índices de vegetação foram separados em duas classes, valores altos (vegetação) e valores baixos (outros objetos) usando o algoritmo de limiarização automático de Otsu conforme descrito em Otsu (1979). A finalidade de automatizar o processo leva em conta o alto número de imagens a serem processadas. Essa etapa foi feita separadamente para cada data e índice de vegetação. Verificou-se que o limiar não é único para todo o ano. As variações para os valores do limiar mínimo se devem às condições radiométricas de cada imagem, sendo que quanto maior esse valor significa que a imagem possui menor contraste.

A operação de limiar é vista como o particionamento dos pixels de uma imagem em duas classes: objeto (C_1) e fundo (C_2). Nesse caso podemos descrever que $C_1 = \{0, 1, \dots, T\}$ e $C_2 = \{T + 1, T + 2, \dots, G - 1\}$, sendo: T o limiar escolhido e G o número de níveis de intensidade da imagem.

Para o índice de vegetação NDVI, os valores dos limiares foram determinados de forma manual em três datas (junho de 2014, dezembro de 2014 e junho de 2015). Esse procedimento foi necessário para melhor ajustar as imagens binárias resultantes da limiarização com a verdade de campo. Na TABELA 9 pode-se ver os valores dos limiares para o índice NDVI sendo que os valores em parênteses correspondem aqueles abandonados e substituídos pelo limiar escolhido manualmente.

TABELA 9 - VALORES DOS LIMIARES USADOS NO ÍNDICE NDVI

Mês	2013	2014	2015
5	203	221	199
6	207	(194)/185	(206)/199
7	198	208	180
8	190	191	194
9	172	193	192
10	172	195	186
11	185	195	198
12	204	(213)/205	212

FONTE: o autor (2017).

Na TABELA 10 pode-se ver os valores dos limiares usados para o índice de vegetação SAVI. Duas imagens (mês 10 de 2013 e mês 11 de 2014) encontram-se fortemente afetadas pela presença de nuvens. Por isso não foram usadas. Em seu lugar foi utilizada a imagem do mês anterior.

TABELA 10 - VALORES DOS LIMIARES PARA O ÍNDICE SAVI

Mês	2013	2014	2015
5	231	193	219
6	185	223	184
7	173	182	204
8	163	168	171
9	194	168	172
10	194	168	163
11	212	168	170
12	194	197	193

FONTE: o autor (2017).

5.4 CODIFICAÇÃO BINÁRIA: SÉRIES ANUAIS

Na sequência as imagens binárias de cada mês foram combinadas para se obter uma imagem representativa do ano. Esta transformação foi executada aplicando a codificação binária. A codificação binária é uma prática usada para resumir imagens hiperespectrais, conforme descrito em Jia e Richards (1993).

De acordo com Xie et al. (2011) o uso da codificação binária visa reduzir a quantidade de dados, preservando o máximo de informações possível podendo melhorar a interpretação de forma automática onde as regiões são consideradas um segmento integrado na classificação.

A codificação binária correspondente a um ano foi calculada conforme a Equação 23.

$$CB = p * 2^{q-1} \quad (23)$$

Onde:

CB é a imagem resultante da codificação binária;

p representa o valor digital lido na imagem binária (0 ou 1, coeficiente limiar específico), e

q o número da imagem, que pode variar de 1 a 8 ao longo do ano seguindo uma ordem cronológica.

5.4.1 Análise anual

A codificação binária equivale a atribuir um peso diferente para cada mês, em uma escala crescente iniciando com o peso 1 para o mês de maio e dobrando seu valor para cada mês subsequente, sendo que no último mês, dezembro, o valor para o peso é de 128 como pode ser visto na TABELA 11.

TABELA 11 - VALORES DOS PESOS PARA CADA MÊS E SUA COMBINAÇÃO

Mês	Peso	Combinação de somas para as imagens multitemporais							
Maio	1	1	1	1	1	1	1	1	1
Junho	2		1	1	1	1	1	1	1
Julho	4			1	1	1	1	1	1
Agosto	8				1	1	1	1	1
Setembro	16					1	1	1	1
Outubro	32						1	1	1
Novembro	64							1	1
Dezembro	128								1
	Valor de CB	1	3	7	15	31	63	127	255

FONTE: o autor (2017).

Dessa forma é possível acompanhar a evolução da presença ou não de vegetação. Como exemplo se todos os meses houver vegetação na imagem binária (valor 1), conseqüentemente a soma é de 255 o valor máximo possível para as 8 imagens combinadas. Caso existam valores para vegetação apenas nos quatro primeiros meses (maio a agosto, por exemplo) esse valor de soma passa a ser 15. Se uma área não possui vegetação em nenhum mês, o valor do contador é zero.

Os valores obtidos nas imagens, quando visualizados na tela do computador são representados por tons de cinza, onde zero é preto e 255 é branco. A inspeção visual das imagens, com suporte da TABELA 12 permite analisar a variação sazonal das culturas e outros alvos na cena.

TABELA 12 – VALORES DO NÍVEL DE CINZA MÍNIMO E MÁXIMO PARA CADA CLASSE.

Classe	NC mínimo	NC máximo
Vegetação permanente	240	255
Soja tardia sem rotação	128	224
Rotação de algodão safrinha e soja precoce	193	199
Rotação de algodão safrinha e soja tardia	129	135
Algodão safra ciclo longo sem rotação	31	63
Algodão safra ciclo curto sem rotação	1	15
Soja precoce sem rotação	96	112

FONTE: o autor (2017).

De posse da verdade de campo, é possível selecionar áreas de verificação, para estimar a acurácia do uso da codificação binária na detecção de alterações em talhões onde a distribuição das classes de uso foi mais homogênea e que sofreu menor interferência de nuvens ao longo da série temporal.

5.4.2 Composição multitemporal

O processo de codificação binária foi repetido para os três anos em estudo: 2013, 2014 e 2015. Com isso foram obtidas 3 imagens de 8 bits cada uma.

Através da combinação das imagens multitemporais, uma em cada canal, é gerada uma imagem colorida, chamada de multianual.

5.5 VEGETAÇÃO PERMANENTE

Alvos como a mata galeria ou ciliar e o cerrado não sofrem alterações significativas ao longo do ano, logo eles aparecem sempre com valores altos do índice de vegetação. Sendo assim, eles teriam um valor igual a 1 em todas as imagens segmentadas, em todos os anos, o que resultaria em um valor codificado de 255. Porém, devido à presença de nuvens, em alguns meses, estes pixels aparecem mais escuros, especialmente em 2013. Para contornar este problema, a vegetação permanente foi identificada nas três imagens e os resultados comparados. Se um pixel apresenta valor de 255 em pelo menos uma das séries, então é assumido que ele é vegetação permanente. Logo, o valor de 255 é usado em todas as séries codificadas, assumindo que qualquer valor diferente é causado pela sombra de nuvens. Com isto, a área de vegetação permanente é igual em todas as imagens multitemporais.

5.5.1 Mata galeria ou ciliar

De acordo com Sano et al. (2008), a mata de galeria ou “floresta ripária” apresenta vegetação verde ao longo do ano, que forma corredores ao longo da rede hidrográfica, com predomínio de espécies arbóreas com altura média das árvores variando entre 20 e 30 metros, além da superposição das copas que permite cobertura arbórea de 70 a 95%. A umidade relativa é alta no seu interior, mesmo durante a época mais seca do ano (julho e agosto).

5.5.2 Cerrado

De acordo com Felfili e Silva Júnior (1993), o Cerrado é considerado a segunda maior formação vegetal brasileira com 3,5 milhões de km², sendo que a classe do Cerrado *sensu strictu* ocupa 70% do total dessa área, caracterizado pela presença de árvores baixas, tortuosas e inclinadas, com os arbustos e subarbustos espalhados. Kawakubo et al. (2004), descrevem que a região do cerrado, corresponde às áreas de vegetação xeromórfica com fisionomia diversa, de arbórea densa, com porte quase florestal até gramíneo lenhosa, fisionomia essencialmente campestre.

5.6 CLASSIFICAÇÃO DAS IMAGENS

A classificação das imagens foi feita por dois métodos diferentes:

- a) Classificação anual e análise pós-classificação;
- b) Classificação da combinação RGB das imagens codificadas.

Para identificação das classes, as mesmas foram identificadas de acordo com a cobertura/uso do solo, com base nos relatórios de campo, como é possível ver na TABELA 13.

TABELA 13- CLASSES E COBERTURA/USO DO SOLO.

Valor	Classe
1	Vegetação permanente (nativa);
2	Soja tardia sem rotação;
3	Rotação de algodão safrinha e soja precoce;
4	Rotação de algodão safrinha e soja tardia;
5	Algodão safra ciclo longo sem rotação;
6	Algodão safra ciclo curto sem rotação
7	Soja precoce sem rotação.

FONTE: o autor (2017).

Para cada uma dessas classes foi encontrado um valor mínimo e máximo para o nível de cinza que permite classificar o uso de cada talhão em função da distribuição temporal da cultura. Por exemplo para a classe “soja tardia sem rotação” que é plantada apenas em dezembro o valor do nível de cinza é igual a 128 (128 que corresponde ao peso para aquele mês), enquanto se a mesma classe foi plantada em outubro o valor do nível de cinza passa a ser 224 ($32 + 64 + 128$) que corresponde à soma dos pesos de todos os meses (outubro a dezembro). A combinação de valores possíveis para o nível de cinza para cada classe pode ser vista na TABELA 12.

5.6.1 Classificação anual

As imagens do índice NDVI foram processadas para cada ano (2013 a 2015) de forma separada com o emprego do método de classificação não supervisionado

ISODATA onde se obteve os *clusters* (agrupamentos ou nuvens) que gerou as classes. Esse método foi escolhido para que as diferentes classes encontradas em cada ano pudessem ser representadas de maneira equivalente.

A sequência para agrupamento seguida foi:

- a) Determinação do número de clusters pelo algoritmo ISODATA (Multispec com classificação não-supervisionada) partindo do número de picos encontrados no histograma das imagens;
- b) Classificação pelo método da Mínima Distância Euclidiana obtendo-se as classes de uso do solo com as rotações de cultura e áreas de vegetação permanente;
- c) Comparação das classes temáticas e a verdade de campo;
- d) Agrupamento das classes que apresentam similaridade quanto à cronologia do ciclo vegetativo na área.

5.6.2 Análise de Detecção das Mudanças Interanuais

Em seguida foi efetuada a análise da variação do uso da terra, chamada aqui de Análise de Detecção das Mudanças Interanuais, “ADMI”, considerando os três anos estudados. Nessa etapa cada imagem gerada na classificação anual foi colocada em um canal RGB diferente. Dessa forma foi possível detectar as variações entre os anos para cada área em uma única imagem. Para obter a imagem empregando essa análise foi usada a Equação 24.

$$Vma = 100 \cdot C(2013) + 10 \cdot C(2014) + 1 \cdot C(2015) \quad (24)$$

Onde:

Vma: combinação dos valores do uso da terra para cada ano;

C(i) é o valor do rótulo na imagem do ano “i”.

TABELA 14 - VALOR QUE IDENTIFICA CADA TIPO DE VARIAÇÃO TEMPORAL

Valor	Descrição
0	Soja
1	Rotação soja/algodão
2	Algodão

FONTE: o autor (2017).

Os valores “100”, “10” e “1” correspondem ao peso para cada ano, onde é feita a multiplicação pelo rótulo em função do uso do solo (soja, rotação ou algodão).

Nesta nova imagem, os valores sem alteração ao longo dos três anos foram agrupados em uma classe “sem alteração” e os restantes foram analisados para identificar as principais mudanças interanuais.

A análise pós-classificação concentrou-se nas áreas dos cultivos dentro das fazendas em estudo, pois nelas se dispõe de áreas de verdade de campo. Assim sendo, os tipos de variação temporal foram aqueles mostrados na TABELA 14, considerando apenas os tipos de cultivo. Os resultados podem ser extrapolados às áreas vizinhas, mas não se conta com informação do uso real nestas regiões.

Considerando os valores produzidos pela Equação 24, cada tipo de variação temporal é associado a um número entre 0 e 222. Por exemplo, um pixel que apresenta soja nos três anos recebe o valor 000. Já se o pixel apresenta a série soja-algodão-soja, o valor seria 020.

5.6.3 Classificação da imagem multianual do índice NDVI

Para essa classificação, a imagem resultante usada foi a multianual. A mesma é obtida pela composição das três imagens multitemporais de cada ano, onde cada uma está contida em uma banda espectral, sendo 2013 no vermelho, 2014 no verde e 2015 na banda azul. Do mesmo modo a partir dos *clusters* encontrados pelo algoritmo ISODATA no Multispec, foi feita a classificação na imagem e em seguida a comparação com as imagens multitemporais de cada ano encontradas na classificação descrita no item 5.6.1.

5.6.4 Avaliação da classificação

De acordo com Congalton (1991), é necessário que se faça uma avaliação da qualidade das técnicas envolvidas no processamento de imagens digitais seja para sensoriamento remoto ou fotogrametria, especialmente na classificação de imagens dada a sua complexidade. O coeficiente Kappa, descrito em Cohen (1960) foi usado como medida de exatidão da classificação. Por esse coeficiente é possível testar o grau de concordância entre a realidade e os resultados de classificação contidos numa matriz de confusão ou erro e que o grau de exatidão é expresso entre 0 e 1. Quanto mais próximo do valor 1, mais a classificação aproxima-se da realidade. O cálculo do coeficiente Kappa pode ser feito através da Equação 25.

$$K = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n (G_i C_i)}{N^2 - \sum_{i=1}^n (G_i C_i)} \quad (25)$$

Onde:

i : é o número de classe;

N : é o número total de pixels classificados que estão sendo comparado a verdade terrestre;

$m_{i,i}$: é o número de pixels que pertencem à classe verdade de campo i , que também foram classificados com uma classe i (isto é, valores encontrados ao longo da diagonal da matriz de confusão);

C_i : é o número total de pixels classificados pertencente a classe i ;

G_i : é o número total de terra verdade pixels pertencentes à classe i .

6. RESULTADOS

6.1 CORREÇÃO RADIOMÉTRICA

A correção radiométrica foi feita no software QGIS, com o emprego do complemento “*Semi-Automatic Classification Plugin*” ou SCP. Para o sensor OLI do satélite LANDSAT 8, são usadas as bandas: 2,3,4,5,6 e 7. Para o sensor ETM⁺ do satélite LANDSAT 7 as bandas usadas são: 1,2,3,4,5 e 7. Como exemplo de aplicação é mostrada na TABELA 15 os valores de radiância multiplicada e somada, reflectância multiplicada e somada, além da radiância e reflectância máxima para cada uma das seis bandas corrigidas para o sensor OLI do satélite LANDSAT 8 que corresponde à imagem do dia 08/09/2015. Para essa data a elevação do sol foi de 46,83 graus e a distância sol-terra igual a 1,0141555 unidade astronômica (UA).

TABELA 15 - VALORES DE RADIÂNCIA E REFECTÂNCIA PARA SEIS BANDAS DA IMAGEM LANDSAT 8 DO DIA 08/09/2015 PARA A CENA ESTUDADA QUANDO FEITA A CORREÇÃO RADIOMÉTRICA.

Banda	Radiancia Multiplicada	Radiancia Somada	Reflectancia Multiplicada	Reflectancia Somada	Radiancia Máxima	Reflectancia Máxima
2	1.2501 E-02	-62.50415	2.0000E-05	-0.100000	756.73773	1.210700
3	1.1519 E-02	-57.59704	2.0000E-05	-0.100000	697.32733	1.210700
4	9.7138 E-03	-48.56907	2.0000E-05	-0.100000	588.02570	1.210700
5	5.9444 E-03	-29.72185	2.0000E-05	-0.100000	359.84241	1.210700
6	1.4783 E-03	-7.39155	2.0000E-05	-0.100000	89.48953	1.210700
7	4.9827 E-04	-2.49135	2.0000E-05	-0.100000	30.16276	1.210700

FONTE: o autor (2017).


Na FIGURA 14 e na FIGURA 15 são mostradas as imagens para duas datas (08/09/2015 e 26/12/2014 respectivamente) onde é possível ver a mesma cena de parte da área de estudo antes da correção radiométrica (à esquerda) e após a correção radiométrica (à direita) feita com o software QGIS, no método DOS (*Dark Object Subtract*). Nesse caso é apresentada uma imagem isenta de nuvens e sombra (mês de setembro) e outra no final do ano (mês de dezembro) onde há maior nebulosidade.

FIGURA 14- IMAGEM LANDSAT 8 DO DIA 08/09/2015 (COMPOSIÇÃO 6,5,4) ANTES DA CORREÇÃO RADIOMÉTRICA (ESQUERDA) E APÓS A MESMA (DIREITA).



FONTE: o autor (2017).


FIGURA 15- IMAGEM LANDSAT 8 DO DIA 26/12/2014 (COMPOSIÇÃO 6,5,4) ANTES DA CORREÇÃO RADIOMÉTRICA (ESQUERDA) E APÓS A MESMA (DIREITA).



FONTE: o autor (2017).


Na FIGURA 16 e na FIGURA 17 são apresentados os histogramas das imagens dos dias 08/09/2015 e 26/12/2014, respectivamente, para melhor visualização da distribuição estatística dos níveis de cinza em função do número de amostras ("pixels").

FIGURA 16 – HISTOGRAMA DAS IMAGENS LANDSAT 8 DO DIA 08/09/2015 (COMPOSIÇÃO 6,5,4) ANTES DA CORREÇÃO RADIOMÉTRICA (ESQUERDA) E APÓS A MESMA (DIREITA).



FONTE: o autor (2017).

FIGURA 17 - HISTOGRAMA DAS IMAGENS LANDSAT 8 DO DIA 26/12/2014 (COMPOSIÇÃO 6,5,4) ANTES DA CORREÇÃO RADIOMÉTRICA (ESQUERDA) E APÓS A MESMA (DIREITA)




FONTE: o autor (2017).

6.2 CORREÇÃO GEOMÉTRICA

A correção geométrica ou registro de todas as imagens foi feita no software ENVI 4.5. A imagem do dia 08/09/2015 foi aquela usada como referência (base) para o registro das demais datas. Essa data foi escolhida por se apresentar isenta de nuvens. Para ilustração, na FIGURA 18 são mostrados os pontos de controle usados quando feito o registro da imagem do dia 07/08/2015. Para essa data foram

determinados doze pontos de controle distribuídos pela cena de forma a cobrir toda sua área com RMS de 0,2207.

FIGURA 18- DISTRIBUIÇÃO DOS 12 PONTOS DE CONTROLE (EM VERMELHO) NAS IMAGENS LANDSAT 8 (BANDA DO INFRAVERMELHO PRÓXIMO) NAS DATAS DE 08/09/2015 (BASE), À DIREITA E 07/08/2015 (REGISTRADA) À ESQUERDA



FONTE: o autor (2017).

Na FIGURA 19 que corresponde à tela “*Image to Image GCP List*” são mostrados os valores dos erros cometidos em “X” e “Y”, além do erro quadrático médio (RMS) para cada um dos doze pontos da imagem de 07/08/2015 quando referenciada à imagem base (08/09/2015).

FIGURA 19- TELA DO ENVI MOSTRANDO A FUNÇÃO “IMAGE TO IMAGE GCP LIST” COM OS PONTOS DE CONTROLE SELECIONADOS PARA A IMAGEM 150807 DO DIA 07/08/2015.

	Base X	Base Y	Warp X	Warp Y	Predict X	Predict Y	Error X	Error Y	RMS
#1+	270.67	798.56	240.56	798.33	240.7219	798.4526	0.1619	0.1226	0.2031
#2+	90.22	1075.56	60.56	1075.44	60.3341	1075.4446	-0.2259	0.0046	0.2259
#3+	89.44	125.78	59.44	125.44	59.5274	125.5814	0.0874	0.1414	0.1663
#4+	854.78	67.67	824.44	67.67	824.5214	67.7405	0.0814	0.0705	0.1077
#5+	807.33	1133.78	777.44	1133.67	777.2788	1133.7382	-0.1612	0.0682	0.1751
#6+	403.44	1093.67	373.33	1093.56	373.4791	1093.5892	0.1491	0.0292	0.1520
#7+	417.33	104.44	387.56	104.56	387.2717	104.3541	-0.2883	-0.2059	0.3543
#8+	119.44	604.44	89.44	604.44	89.5308	604.2901	0.0908	-0.1499	0.1752
#9+	835.56	636.56	805.22	636.78	805.4126	636.5688	0.1926	-0.2112	0.2858
#10+	582.56	417.67	552.67	417.33	552.4690	417.6311	-0.2010	0.3011	0.3621
#11+	325.44	509.67	295.33	509.67	295.4533	509.5639	0.1233	-0.1061	0.1627
#12+	526.56	926.56	496.56	926.56	496.5499	926.4956	-0.0101	-0.0644	0.0652

FONTE: o autor (2017).

Para as demais datas foi feito o mesmo processo de registro com o emprego de 9 a 12 pontos de controle para cada imagem. O número de pontos de controle e RMS obtidos para cada imagem para cada ano da série temporal são apresentados na TABELA 16 (ano de 2013), TABELA 17 (ano de 2014) e na TABELA 18 (ano de 2015).

TABELA 16 - VALORES DE RMS (ROOT MEAN SQUARE) E NÚMERO DE PONTOS DE CONTROLE PARA CADA IMAGEM DO ANO 2013 COM BASE NA IMAGEM 150908.

Imagens 2013	RMS	Número de pontos de controle
130505	0,3567	11
130614	0,2207	10
130716	0,1079	10
130817	0,1758	11
130926	0,3672	10
131113	0,4312	10
131213	0,3870	10
Média	0,2923	

FONTE: o autor (2017).

TABELA 17 - VALORES DE RMS (ROOT MEAN SQUARE) E NÚMERO DE PONTOS DE CONTROLE PARA CADA IMAGEM DO ANO 2013 COM BASE NA IMAGEM 150908.

Imagens 2014	RMS	Número de pontos de controle
140516	0,1309	9
140609	0,3000	11
140703	0,2036	10
140820	0,1491	10
140905	0,3315	9
141007	0,1957	11
141226	0,2587	10
Média	0,2242	

FONTE: o autor (2017).

TABELA 18 - VALORES DE RMS (ROOT MEAN SQUARE) E NÚMERO DE PONTOS DE CONTROLE PARA CADA IMAGEM DO ANO 2013 COM BASE NA IMAGEM 150908.

Imagens 2015	RMS	Número de pontos de controle
150527	0,3144	9
150620	0,2434	11
150730	0,2986	11
150807	0,2207	12
151026	0,2861	11
151111	0,3174	12
151213	0,2696	10
Média	0,2786	

FONTE: o autor (2017).


6.3 IMAGENS BINÁRIAS

Os valores digitais de cada alvo nas imagens estão representados em 8 bits (1 byte) por canal originalmente. Após a limiarização esses dados passam a ser representados por apenas 1 bit (imagem binária). Nessa imagem, os alvos de interesse são representados em duas classes, vegetação (em branco) e não vegetação (em preto).

Na FIGURA 20 são mostradas duas imagens do mesmo ano (2015) para os meses de agosto e novembro onde é feita uma comparação da cobertura vegetal. É

possível evidenciar, na imagem do período mais seco (agosto), que a área coberta por vegetação é menor em relação a novembro devido à baixa umidade do solo.

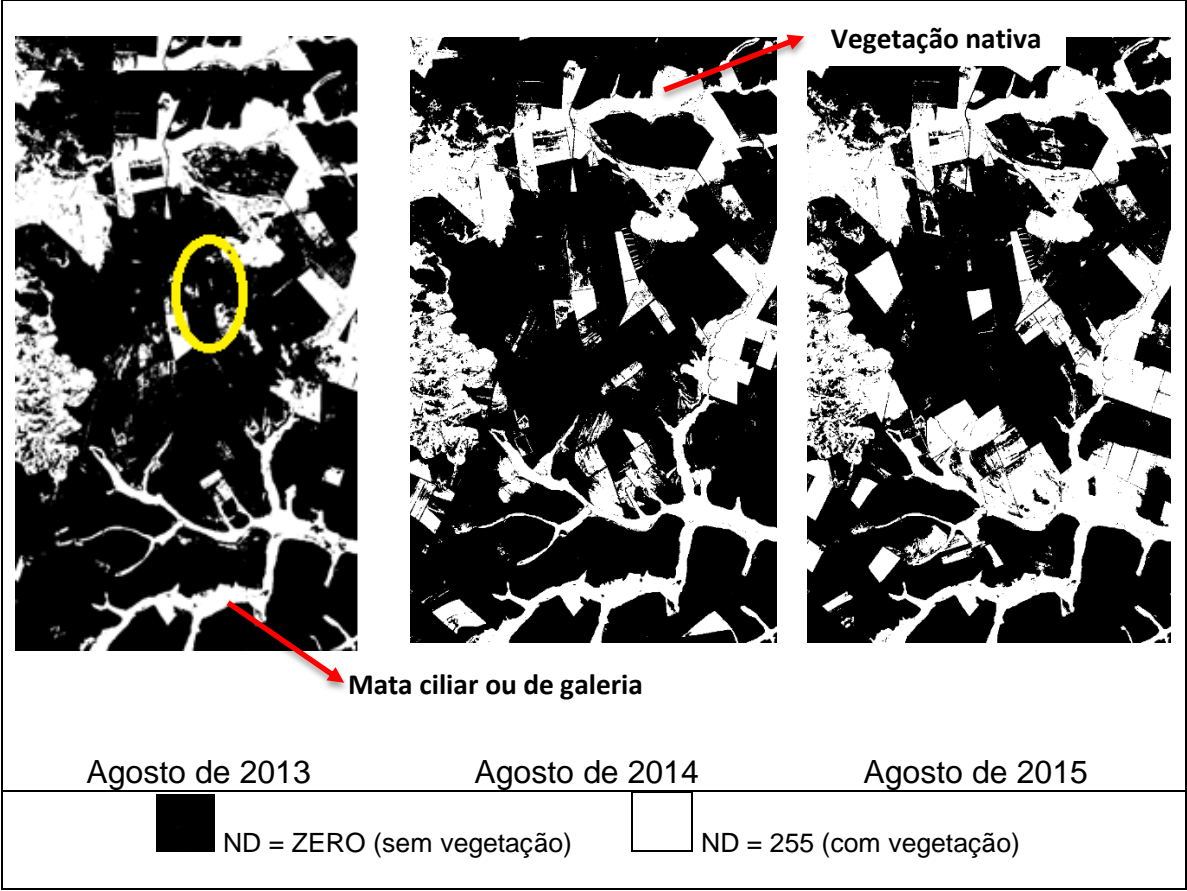
FIGURA 20 - COMPARAÇÃO DE DUAS IMAGENS BINÁRIAS DO ÍNDICE NDVI PARA UM MÊS SECO (AGOSTO) IMAGEM À ESQUERDA E UM MÊS ÚMIDO (NOVEMBRO) IMAGEM À DIREITA.



FONTE: o autor (2017).

O processo de limiarização das imagens foi adequado para todas as épocas em cada ano estudado quando usado nas imagens do índice NDVI. Na FIGURA 21 é mostrada a comparação das imagens binárias do NDVI para o mesmo mês (agosto) nos três anos estudados (2013 a 2015). Nessa série é possível visualizar a vegetação de Mata ciliar ou de galeria ao sul da cena e uma faixa de vegetação nativa ao norte da cena com Cerrado *senso strictu*. Uma diferença nítida entre as três datas se refere a uma área de Cerrado que na imagem de 2013 (assinalada em amarelo) é praticamente suprimida em relação aos demais anos.

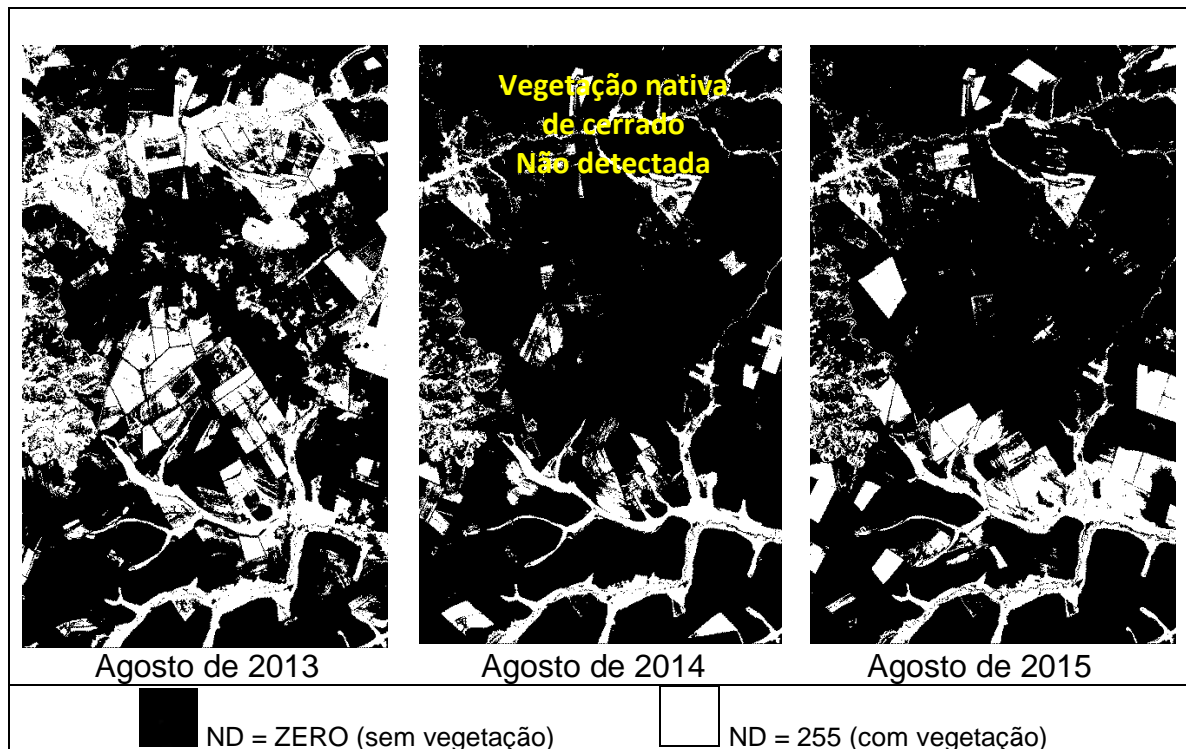
FIGURA 21 - COMPARAÇÃO DAS IMAGENS BINÁRIAS DO ÍNDICE NDVI PARA O MÊS DE AGOSTO NOS TRÊS ANOS ESTUDADOS (2013 A 2015)



FONTE: o autor (2017).

Para a mesma área e época do ano quando empregada a limiarização das imagens usando o índice de vegetação SAVI, nos anos de 2014 e 2015 não há detecção das áreas com vegetação nativa de Cerrado, principalmente no norte da cena como é mostrado na FIGURA 22. Apenas a mata ciliar ao sul da imagem aparece nas imagens do índice de vegetação SAVI de forma equivalente com a verdade de campo. Dessa forma o índice de vegetação SAVI não se mostrou adequado para se fazer a classificação das imagens, sendo que o mesmo não foi usado nas etapas posteriores do trabalho.

FIGURA 22. COMPARAÇÃO DAS IMAGENS BINÁRIAS DO ÍNDICE SAVI PARA O MÊS DE AGOSTO NOS TRÊS ANOS ESTUDADOS (2013 A 2015) ONDE SE PODE VER A DEFICIÊNCIA NA DETECÇÃO DE VEGETAÇÃO NATIVA (CERRADO) PARA OS ANOS DE 2014 E 2015



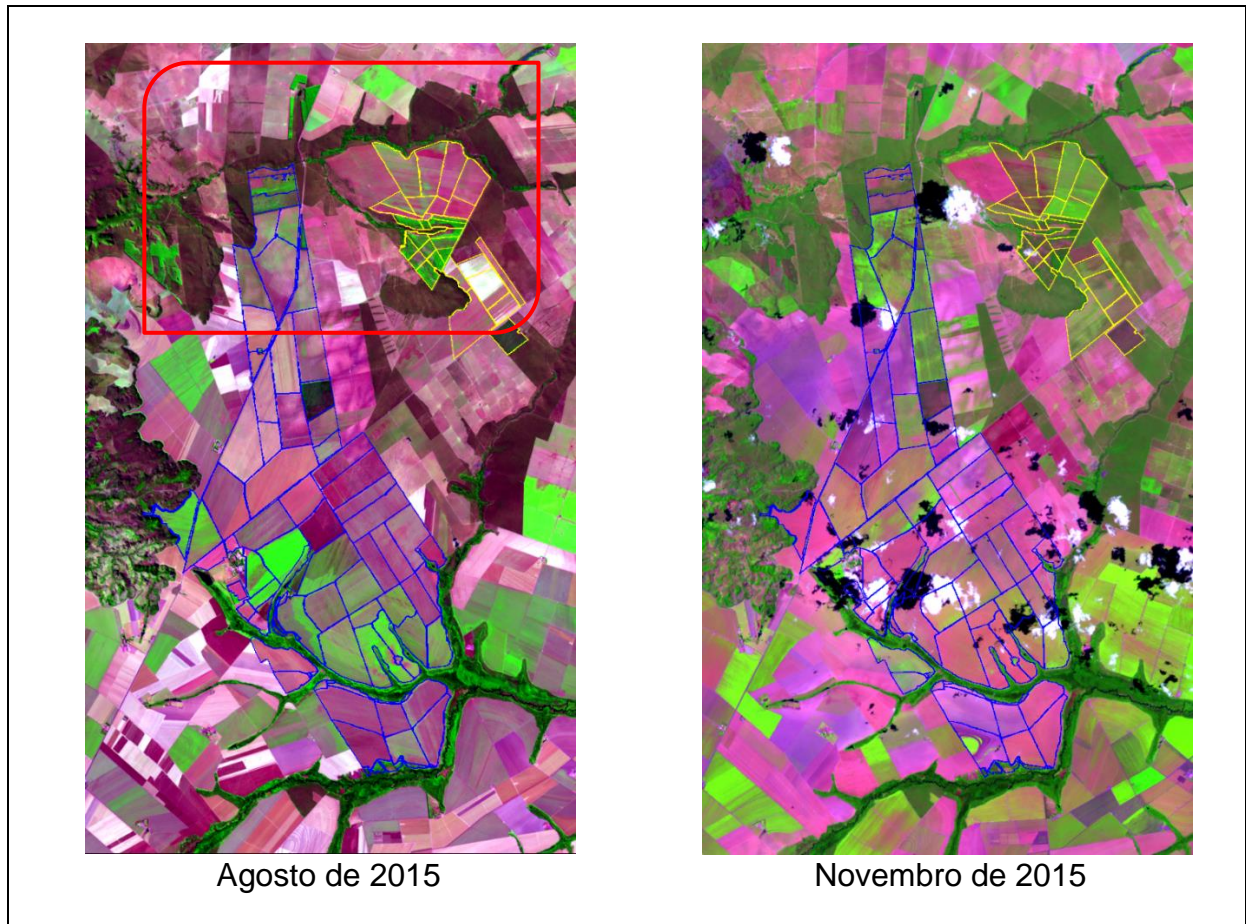
FONTE: o autor (2017).

Esse comportamento do índice de vegetação SAVI para o mês de agosto, que é aquele mostrado na comparação, se deve ao uso do valor “L” igual a 1 nesse trabalho (TABELA 8. VALOR DA CONSTANTE “L” USADA NO CÁLCULO DO SAVI EM FUNÇÃO DA DENSIDADE DE VEGETAÇÃO. Conforme Huete (1988), esse é o valor mais alto usado para o cálculo do índice de vegetação SAVI, que propicia em relação ao índice NDVI uma diferença maior especialmente nas áreas onde a vegetação permanente não possui um mesmo vigor ao longo do ano.

Essa diferença pode ser vista quando é feita a comparação entre duas datas com comportamentos climáticos diferentes, principalmente quanto à umidade (FIGURA 23). Para o mês de agosto (imagem 150807), o período é de seca e para o mês de novembro (imagem 151111) o período é úmido. Na parte norte da imagem a vegetação nativa (Cerrado), assinada em vermelho permite evidenciar o contraste do clima, pois a mesma se apresenta menos exuberante em agosto e com mais vigor em novembro. Essa diferença é devido à vegetação de Cerrado se caracterizar por plantadas caducifólias, que nos meses secos perdem as folhas, além da coloração das mesmas ter uma tonalidade acinzentada, ou seja, sem pigmento verde, ao

contrário da mata ciliar que está presente na porção sul e têm as folhas verdes ao longo do ano. Nas imagens ainda são apresentados os contornos da propriedade estudada (em azul), além da divisão de cada talhão da Fazenda Marabá.

FIGURA 23. COMPARAÇÃO ENTRE AS IMAGENS DE AGOSTO E NOVEMBRO DE 2015 NA COMPOSIÇÃO FALSA COR 6,5,4 PARA O SATÉLITE LANDSAT 8 COM DESTAQUE PARA A VEGETAÇÃO DE CERRADO (ASSINALADO EM VERMELHO)



FONTE: o autor (2016).

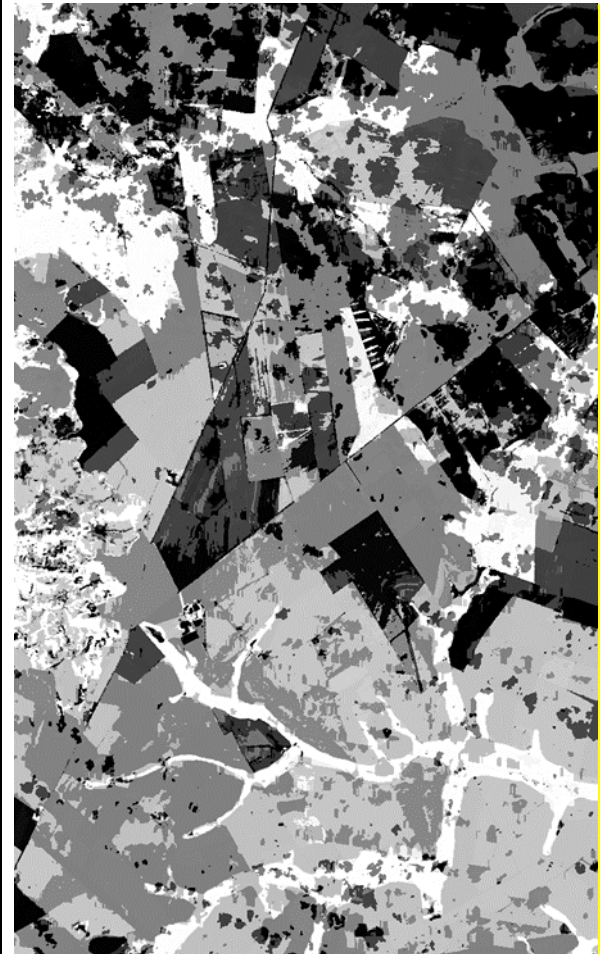






6.4 IMAGENS MULTITEMPORAIS

Após a limiarização de cada imagem, as mesmas foram agrupadas em uma série de 8 imagens correspondendo aos meses de maio a dezembro para os três anos estudados (2013 a 2015). Dessa forma tem-se como resultado uma imagem multitemporal para cada ano que representa as alterações nesse período.

No QUADRO 1 é apresentada uma imagem, correspondente ao ano de 2013, como ilustração. Esta imagem foi construída com as imagens do índice de vegetação NDVI binarizadas, segundo a Equação 23 (equação da codificação binária). O padrão

encontrado nesta imagem é também visível nos outros anos, uma comparação dos três anos é vista na FIGURA 24.

QUADRO 1- IMAGEM APÓS A CODIFICAÇÃO BINÁRIA DO ÍNDICE DE VEGETAÇÃO NDVI PARA O ANO DE 2013

	LEGENDA
	 ND=0 Sem vegetação (Valor 0)
	 ND =1-15 Vegetação no início do ano. Algodão safra sem rotação.
	 ND~63 Vegetação no início do ano. Algodão safrinha sem rotação.
	 ND=127 Vegetação no final do ano. Soja tardia sem rotação.
	 ND=195 Vegetação no início e final do ano. Algodão safrinha em rotação com soja tardia.
	 ND=255 Vegetação em todas as imagens.

FONTE: o autor (2017).

Os valores digitais desta imagem se concentram em três grandes agrupamentos. As regiões cobertas por solo nu, água, asfalto ou outros alvos diferentes da vegetação apresentam sempre valores nulos nas imagens binarizadas. Por isto, sua adição na codificação binária resulta em valores nulos. No caso da água o valor da soma para reflectância é sempre 0 (zero) em todas as datas não havendo variação pois esse é um alvo onde a reflectância é sempre baixa. As estradas geralmente são representadas como linhas retas, escuras e estreitas devido a topografia plana da região.

Um agrupamento com valor característico em torno de 1 a 15 cria outras regiões escuras na imagem, mas estas não são totalmente nulas. Valores baixos são produzidos quando a vegetação está presente apenas no início da série. Esta é a característica dos campos de algodão, uma cultura de início de ano. O resto do ano, o campo fica sem atividade agrícola, ficando com pouca vegetação.

Os valores até 63 caracterizam combinações da codificação binária nas que existem valores significativos no início da série por maior tempo. Consultando o calendário das respectivas fazendas, isto coincide com cultivo de algodão safrinha sem rotação.

A rotação entre soja e algodão é visível com os valores em torno de 195. Neste caso, o período mais coberto por vegetação acontece no final da série de imagens binárias.

Quando a vegetação ocorre apenas no final do ano, um valor de 127 é produzido. Este valor é notado em campos de soja sem rotação, pois esta cultura somente aparece no final do ano, sendo que no restante do período o campo está sem vegetação significativa.

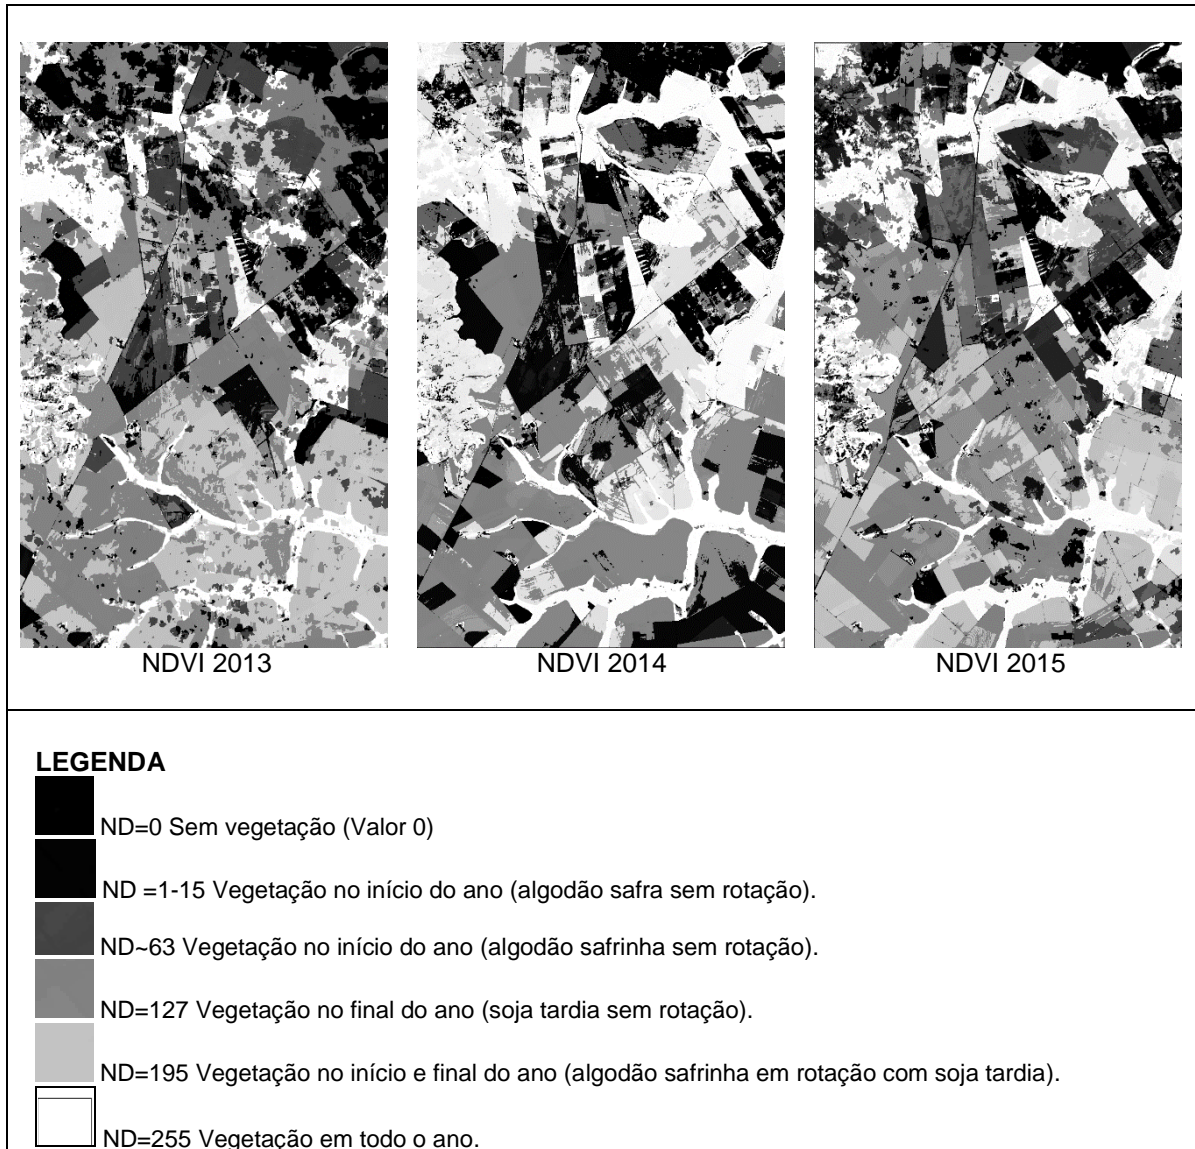
Quando ocorre vegetação em todas as imagens binárias, o pixel é sempre representado pelo valor 1, o que produz o valor de 255 na imagem da codificação binária. Assim sendo, valores 255 correspondem à vegetação permanente como, por exemplo, a mata ciliar ou os bosques de reflorestamento de eucaliptos. Não é possível distinguir estas duas coberturas, neste caso.

A vegetação nativa seja mata ciliar, cerradão ou cerrado aparece em branco ou em coloração bem clara, pois o valor para esses alvos é quase sempre 1 nas imagens binárias. Isso se dá porque essa vegetação se apresenta verde ao longo do ano com pouca variação de cor, mesmo para o período seco (maio a agosto) onde a perda de vigor vegetativo das folhas é mínima em relação ao porte e volume da vegetação.

Alguns exemplos destas tonalidades de cinza podem ser vistos na FIGURA 25, onde um pequeno recorte da imagem codificada é apresentado em ampliação. Nota-se, por exemplo, que valores escuros ocorrem na estrada, que nunca é coberta por vegetação ao longo do ano. A vegetação nativa, sempre presente, aparece bem clara. Os campos de cultivo apresentam tonalidades de cinza médio, pois durante alguns períodos tem vegetação e outros meses estão sem vegetação. Na mesma imagem

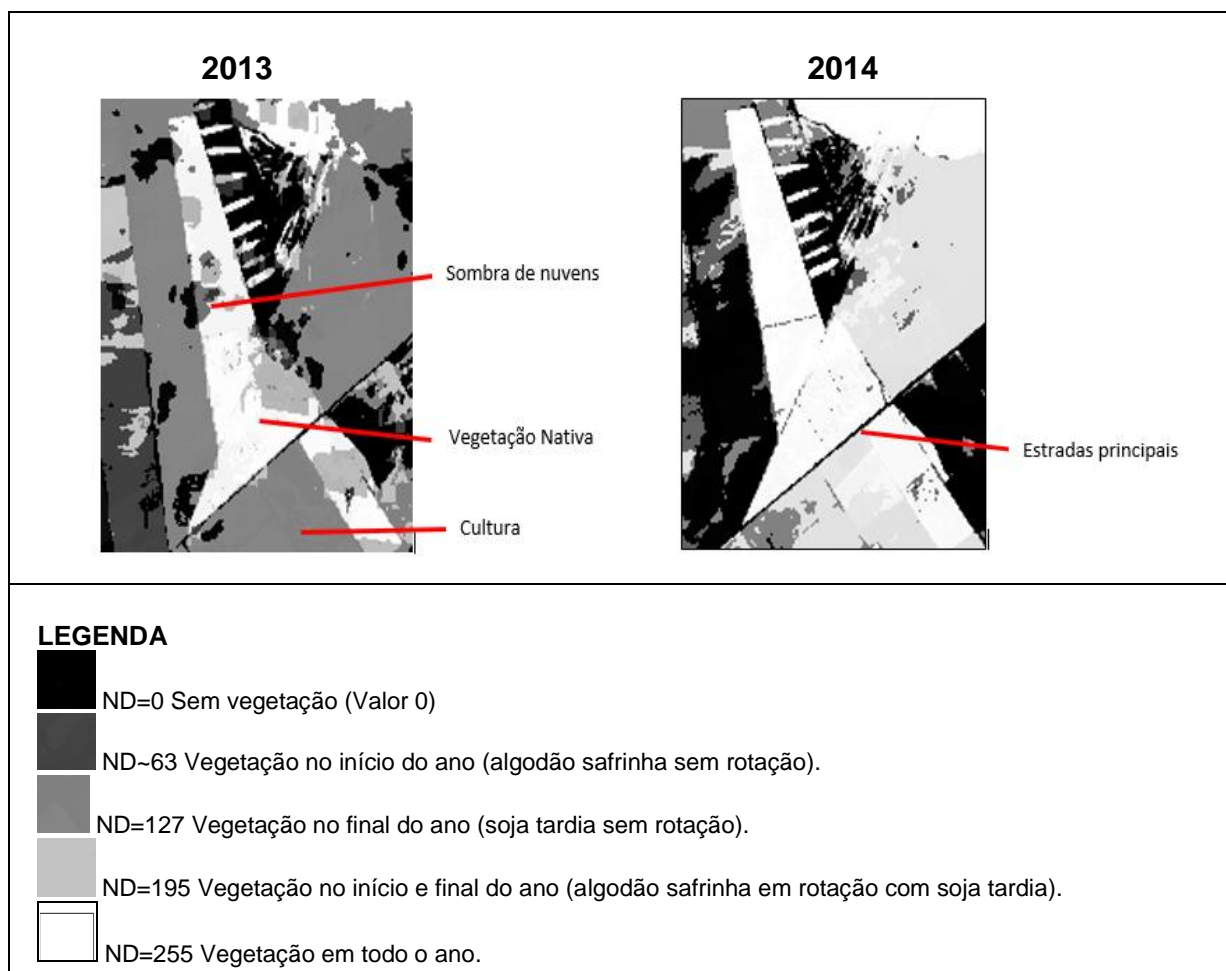
nota-se o efeito das nuvens, que podem causar valores nulos em algumas imagens, mascarando a presença de vegetação.

FIGURA 24 - IMAGENS MULTITEMPORAIS DE CADA ANO ESTUDADO PARA O ÍNDICE DE VEGETAÇÃO NDVI (2013 A 2015).



FONTE: o autor (2017).

FIGURA 25 – IMAGENS MULTITEMPORAIS DO ÍNDICE DE VEGETAÇÃO NDVI PARA UMA MESMA ÁREA NOS ANOS DE 2013 E 2014 COM VEGETAÇÃO DE CERRADO, CULTURAS, SOMBRA DE NUVEM E ESTRADA.



FONTE: o autor (2017).

Os valores verificados nas outras imagens, são similares. A distribuição espacial das tonalidades de cinza, porém são diferentes, o que caracteriza algumas alterações temporais nas práticas de cultivo.

6.4.1 Característica das culturas nas imagens multitemporais


As culturas apresentam uma variação multitemporal ao longo do ano em função do estágio vegetativo das mesmas, como também uma variação interanual, já que para cada ano uma determinada área (talhão) pode ou não ser cultivada. Dessa forma, o valor do nível de cinza é variável em função do número de imagens que são classificadas como vegetação ou não-vegetação e que são contabilizadas ao longo do ano.

Como exemplo, é feita a demonstração de uma pequena área de uma imagem multitemporal representada na FIGURA 26 que permite ver alguns tipos de cultivo em contraste com outros alvos escuros.

Esses alvos são:

- a) Área de cultivo de algodão sem rotação com soja, onde o valor do nível de cinza é baixo pois só existe vegetação verde até o mês de julho, portanto com baixo valor da soma como exposto anteriormente (valor de nível de cinza igual a 7);
- b) Eucaliptos que formam os quebra-ventos ao redor da sede da Fazenda Marabá que estão em branco, pois o valor do nível de cinza é próximo a 255;
- c) Pequena pista de pouso, escuro por se tratar de solo exposto;
- d) Vegetação de gramínea junto a uma várzea (mesma situação do eucalipto);
- e) Pequena represa, preto, por ser água onde a reflectância é muito baixa;
- f) Área de cultivo de algodão e rotação com soja, onde o valor do nível de cinza é intermediário pois só existe vegetação verde nos meses de maio a julho (algodão) como também para novembro e dezembro (soja) que resulta em um valor de nível de cinza aproximado de 199 gerando um tom de cinza mais claro.

FIGURA 26 – ÁREA NO ENTORNO DA SEDE DA FAZENDA MARABÁ ONDE PODEM SER VISTOS DIVERSOS ALVOS ASSINALADOS COM COMPORTAMENTO DIFERENTES QUANTO AO VALOR DO NÍVEL DE CINZA (IMAGEM DO ANO 2013)



FONTE: o autor (2017).

Dessa forma pode-se então afirmar que as culturas estudadas têm comportamento diferente quanto aos valores de nível de cinza encontrados em função da época do ano que as mesmas estão no campo. Exemplificamos essa informação através de uma simulação como se fosse no campo onde é feita a combinação das culturas possíveis, como é mostrado no QUADRO 2.

QUADRO 2 – VALORES DO NÍVEL DE CINZA PARA CADA TIPO DE CULTURA OU ROTAÇÃO NA ÁREA APÓS A COMBINAÇÃO ENTRE O VALOR BINÁRIO (1) E O PESO PARA CADA MÊS

Quadro de combinação de somas para as culturas estudadas										
		Culturas combinadas								
Mês	Peso	Algodão sem rotação				Algodão/Soja			Soja sem rotação	
Maio	1	1	1	1	1	1	1	1		
Junho	2	1	1	1	1	1	1	1		
Julho	4	1	1	1		1	1			
Agosto	8	1	1							
Setembro	16	1								
Outubro	32	1								
Novembro	64						1	1	1	
Dezembro	128					1	1	1	1	1
Soma do NC		63	15	7	3	135	199	195	192	128

FONTE: o autor (2017).

O algodão sem rotação é a cultura que apresenta o valor de nível de cinza mais baixo pois seu ciclo vegetativo ocorre nos meses iniciais da série (maio a julho) onde os pesos apresentam valores pequenos.

A cultura da soja quando cultivada em uma área sem rotação apresenta valores do nível de cinza elevados devido a fase vegetativa com presença de folhas verdes ocorrer no final do ano (outubro a dezembro) onde o valor do peso é maior.

Para a rotação algodão/soja ao longo da série anual, os valores do nível de cinza são um pouco maiores que para a cultura da soja sem rotação, já que é feita soma dos pesos das duas culturas, pois tem-se cultivo no início da série (algodão) e no final da série (soja).

6.5 ANÁLISE PÓS-CLASSIFICAÇÃO

A análise é composta por duas etapas: na primeira cada imagem anual (baseada na multitemporal para cada ano) é classificada usando a classificação não-supervisionada pela Mínima Distância Euclidiana. Na segunda os resultados das três classificações resultantes nas imagens anuais (2013 a 2015) são comparados e são analisadas as variações ou mudanças do uso do solo. A seguir, os resultados destas duas etapas são apresentados.

6.5.1 Classificação anual (2013 a 2015)

A classificação para cada ano, chamada de classificação anual, gerou *clusters* que foram agrupados em classes em função do valor médio, mínimo e máximo do nível de cinza encontrado. As classes adotadas dessa etapa em diante segue aquela descrita no item 5.4.1 da metodologia. Para o ano de 2013 foram encontrados 9 clusters e os valores do nível de cinza para o agrupamento das classes são mostrados na TABELA 19, enquanto que no ano de 2014 foram encontrados 7 clusters e os valores do nível de cinza são mostrados na TABELA 20, e finalmente para o ano de 2015 foram encontrados 10 clusters e os valores do nível de cinza encontrados para o agrupamento das classes são mostrados na TABELA 21.

TABELA 19 - VALORES DO NÍVEL DE CINZA E CLUSTERS EMPREGADOS NA CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2013.

Classe		Clusters agrupados	Valor do nível de cinza			
			Médio	Desvio	Min	Max
1	Vegetação nativa	C1	254	2,1	241	255
2	Algodão safrinha e soja precoce	C2	198	3,6	190	208
		C3	182	3,7	177	189
3	Algodão safrinha e soja tardia	C4	142	1,4	138	144
		C5	131	3,1	123	137
4	Algodão safra sem rotação ciclo curto	C9	1	2,9	0	15
5	Algodão safra sem rotação ciclo longo	C7	67	3,6	60	79
		C8	51	3,1	48	59
6	Soja tardia sem rotação	Não tem				
7	Soja precoce sem rotação	C6	115	2,7	112	122

FONTE: o autor (2017).

TABELA 20 - VALORES DO NÍVEL DE CINZA E CLUSTERS EMPREGADOS NA CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2014.

Classe		Clusters agrupados	Valor do nível de cinza			
			Média	Desvio	Min	Max
1	Vegetação nativa	C1	254	2.5	242	255
2	Algodão safrinha e soja precoce	Não tem				
3	Algodão safrinha e soja tardia	C3	149	6,2	142	160
		C4	133	3,2	117	141
4	Algodão safra sem rotação ciclo curto	C7	3	3,1	0	12
5	Algodão safra sem rotação ciclo longo	C6	21	4.2	13	31
6	Soja tardia sem rotação	C2	230	5.1	225	241
7	Soja precoce sem rotação	C5	100	6,0	96	116

FONTE: o autor (2017).

TABELA 21 - VALORES DO NÍVEL DE CINZA E CLUSTERS EMPREGADOS NA CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2015.

Classe		Clusters agrupados	Valor do nível de cinza			
			Média	Desvio	Min	Max
1	Vegetação nativa	C1	254	1,7	240	255
2	Algodão safrinha e soja precoce	C3	198	5,1	188	211
		C4	176	3,0	170	187
3	Algodão safrinha e soja tardia	C5	163	3,0	148	169
		C6	133	5,3	117	147
4	Algodão safra sem rotação ciclo curto	C10	1	3,3	0	18
5	Algodão safra sem rotação ciclo longo	C9	35	4,7	19	50
		C8	66	3,6	51	82
6	Soja tardia sem rotação	C2	226	4,3	212	239
7	Soja precoce sem rotação	C7	99	4,3	83	116

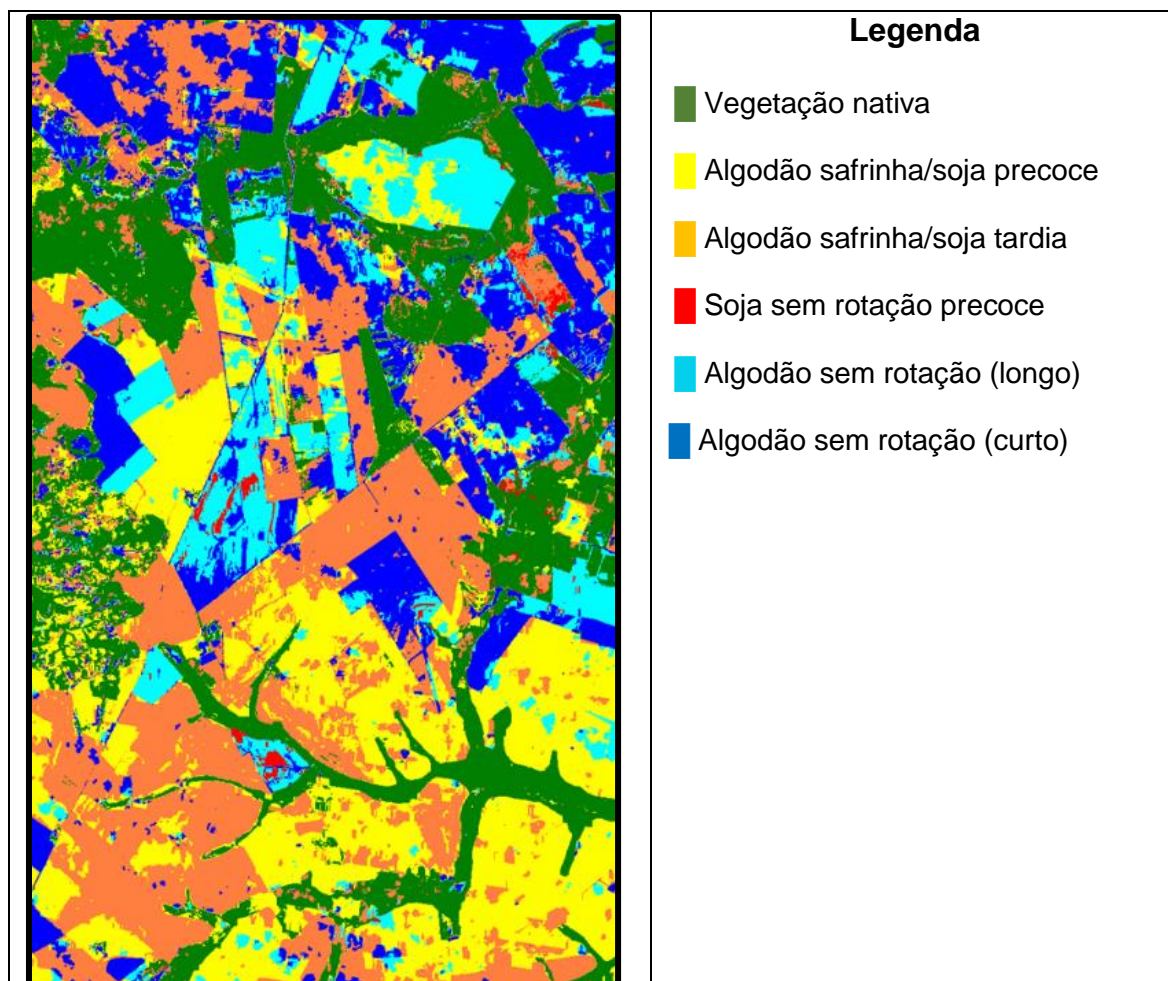
FONTE: o autor (2017).

Na comparação dos três anos, é possível verificar que a classe “vegetação nativa” é aquela que apresenta a menor variação na média do valor do nível de cinza (igual a 254 nos três anos) devido a mesma não sofrer alterações ao longo do ano. Essa classe pode ser usada como referência para medir a acurácia do método de classificação.

Ao analisar as outras seis classes, que são todas áreas agrícolas, ou seja, onde pode ocorrer alterações no período estudado, a classe que apresenta o melhor padrão de identificação é a classe 4 “algodão safra sem rotação ciclo curto”, com valores do nível de cinza igual a 1 para os anos de 2013 e 2015 e valor do nível de cinza igual a 3 para o ano de 2014. Essa classe é bem definida pois os valores encontrados para o nível de cinza são baixos e na classificação a mesma é facilmente separada das demais.


Para cada ano foi gerada a classificação onde é possível ver a distribuição das classes. O mapa da classificação para o ano de 2013 pode ser visto na FIGURA 27, enquanto para o ano de 2014 é visto na FIGURA 28 e para o ano de 2015 na FIGURA 29.

FIGURA 27 - CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2013.



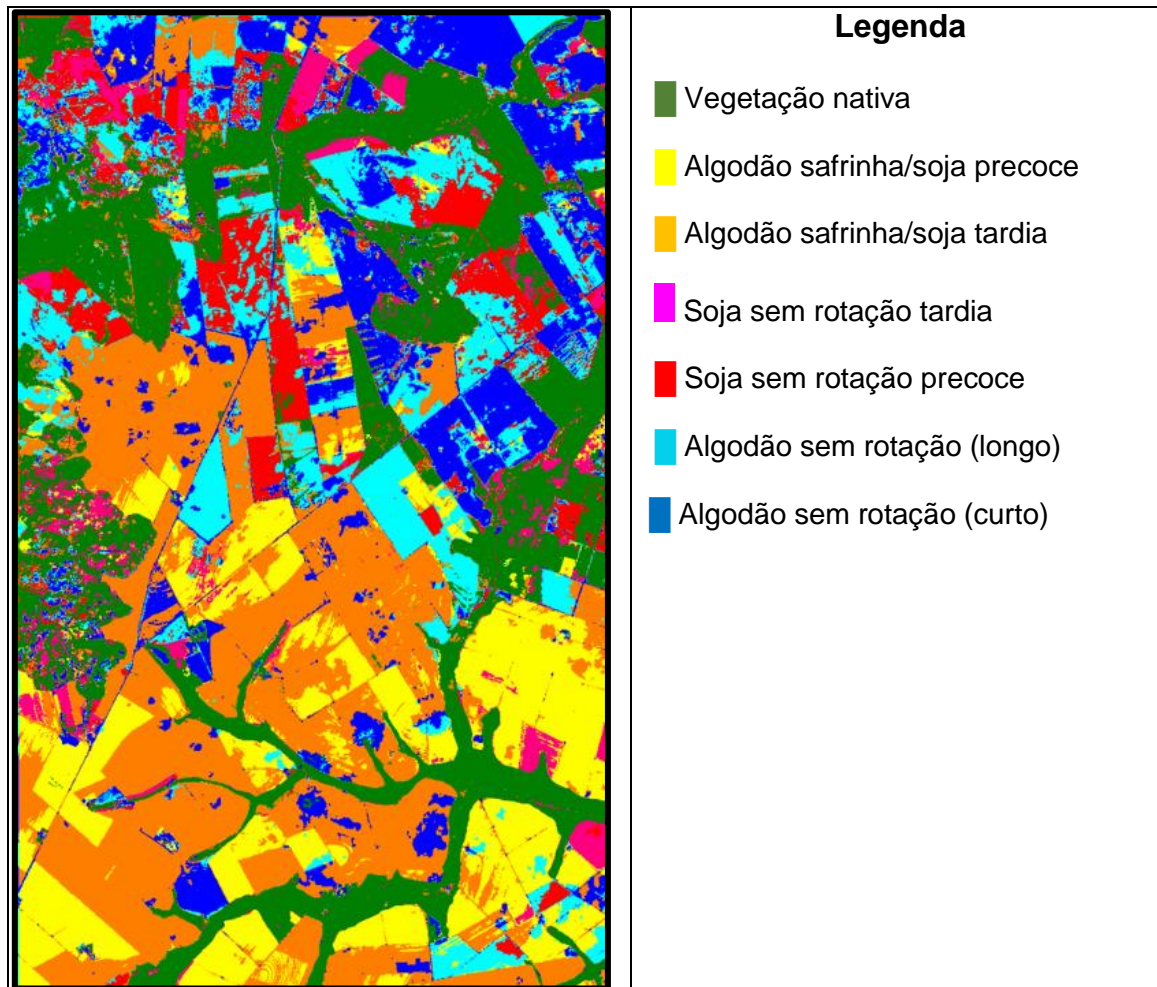
FONTE: o autor (2017).

FIGURA 28 -CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2014.



FONTE: o autor (2017).

FIGURA 29 - CLASSIFICAÇÃO DA IMAGEM MULTITEMPORAL DO ÍNDICE NDVI PARA O ANO DE 2015.



FONTE: o autor (2017).

Na comparação das imagens classificadas para os três anos, é possível observar que para os anos de 2013 e 2015 houve uma menor variação das classes de culturas nos talhões localizados ao sul da imagem, predominando duas classes:

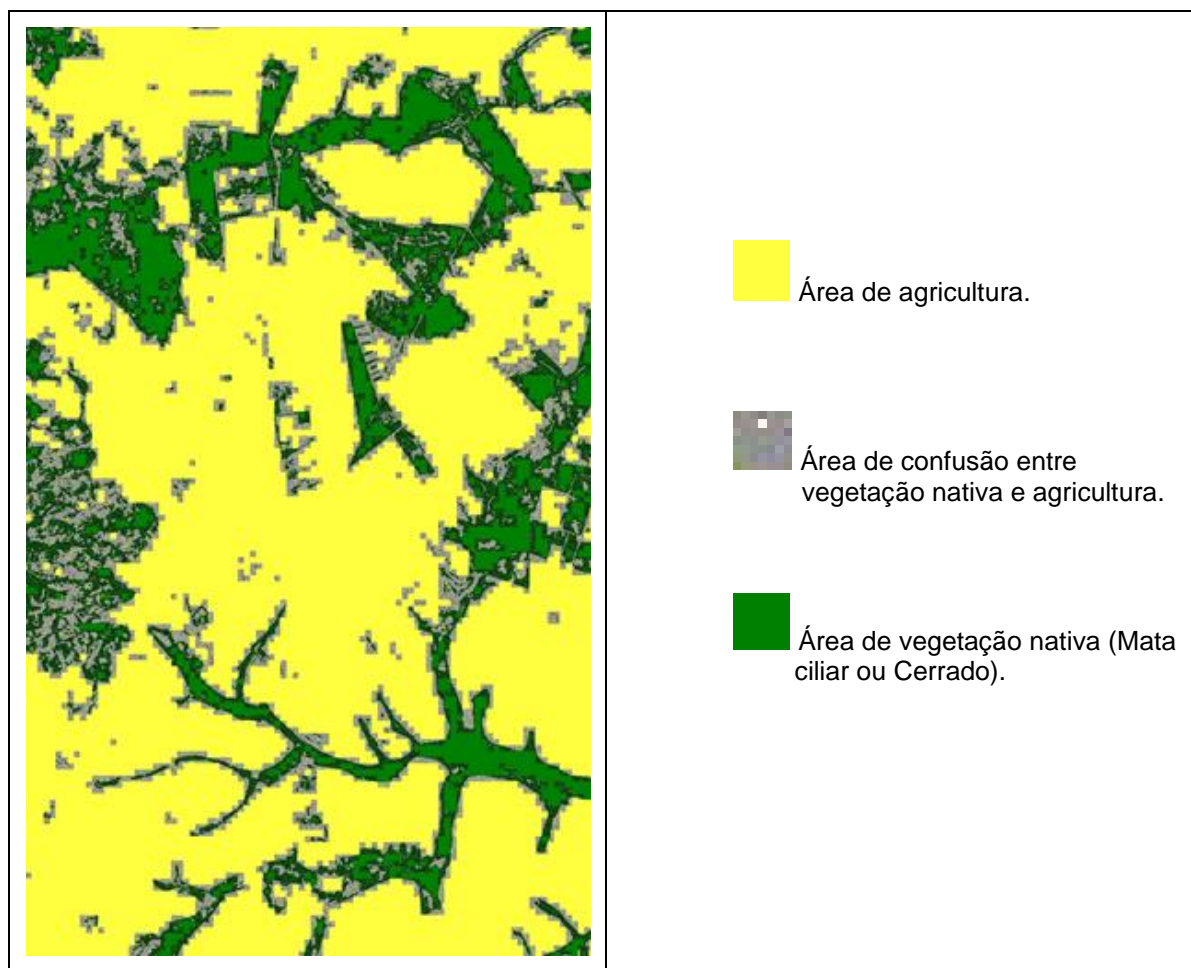
- a) Classe 2 “algodão safrinha/soja precoce” (cor amarela); e
- b) Classe 3 “algodão safrinha/soja tardia” (cor laranja).

Enquanto que para o ano de 2014 nessa mesma área a classe encontrada foi apenas a Classe 3 “algodão safrinha/soja tardia” (cor laranja) e nas demais áreas para esse ano a Classe 6 “soja sem rotação” (cor rosa) apresentou uma grande área cultivada.

Nos três anos a classe que pode ser vista em todas as datas com bastante representação é a Classe 4 “algodão sem rotação ciclo curto” (cor azul escuro), principalmente na porção norte das imagens.

Para melhor exemplificar a distribuição do uso do solo na área, é mostrada na FIGURA 30, a ocupação pelos diferentes tipos de vegetação (nativa e agricultura). Também é mostrada a área onde há confusão na classificação entre agricultura e vegetação nativa, que ocorre onde a vegetação nativa é de pequeno porte que se assemelha à área agrícola.

FIGURA 30 – ÁREA COM AGRICULTURA, VEGETAÇÃO NATIVA E ÁREA COM CONFUSÃO NA CLASSIFICAÇÃO ENTRE AGRICULTURA E VEGETAÇÃO NATIVA.



FONTE: o autor (2017).

6.5.2 Classificação da Análise de Detecção das Mudanças Interanuais

Na FIGURA 31 é possível visualizar as áreas onde não houve detecção de alteração entre os três anos (em branco). Essas áreas correspondem aos talhões com agricultura sem rotação e aquelas onde há vegetação permanente (mata nativa). As áreas em preto são aquelas onde houve alterações (rotação).


FIGURA 31 - EMPREGO DO ÍNDICE NDVI PARA VISUALIZAR ÁREAS ONDE NÃO HOUVE ALTERAÇÕES (BRANCO) NO PERÍODO ESTUDADO (2013 A 2015).



FONTE: o autor (2017).

As áreas com variação entre anos foram a seguir analisadas com o uso da imagem de detecções interanuais. De acordo a Equação 24, cada tipo de variação recebe um número único que vai de 000 a 222. A frequência de cada tipo de variação é mostrada no histograma da FIGURA 32. Nota-se que apenas as classes com variação são representadas.

FIGURA 32 – VALORES DA OCORRÊNCIA EM PIXEL PARA CADA CLASSE NA IMAGEM “ADMI” PARA O PERÍODO ESTUDADO (2013 A 2015).



FONTE: o autor (2017).

O histograma revela quais são os tipos de variação temporal mais frequentes. No eixo “y” é mostrado o valor do número de pixel que possui cada classe, enquanto no eixo “x” estão os tipos codificados. Por exemplo, a variação temporal 121 (rotação-algodão-rotação) é aquela que mais ocorre na imagem. As variações que ocorrem com menor frequência são aquelas onde a cultura da soja é plantada sem rotação somente para o ano de 2013, como é o caso das variações: 001, 002, 010 que estão localizadas no início do histograma. No QUADRO 3 são mostrados os tipos de variação mais frequentes.

QUADRO 3 – TIPOS DE VARIAÇÃO CODIFICADOS E A FREQUENCIA EM QUE OCORREM NA IMAGEM “ADMI”.

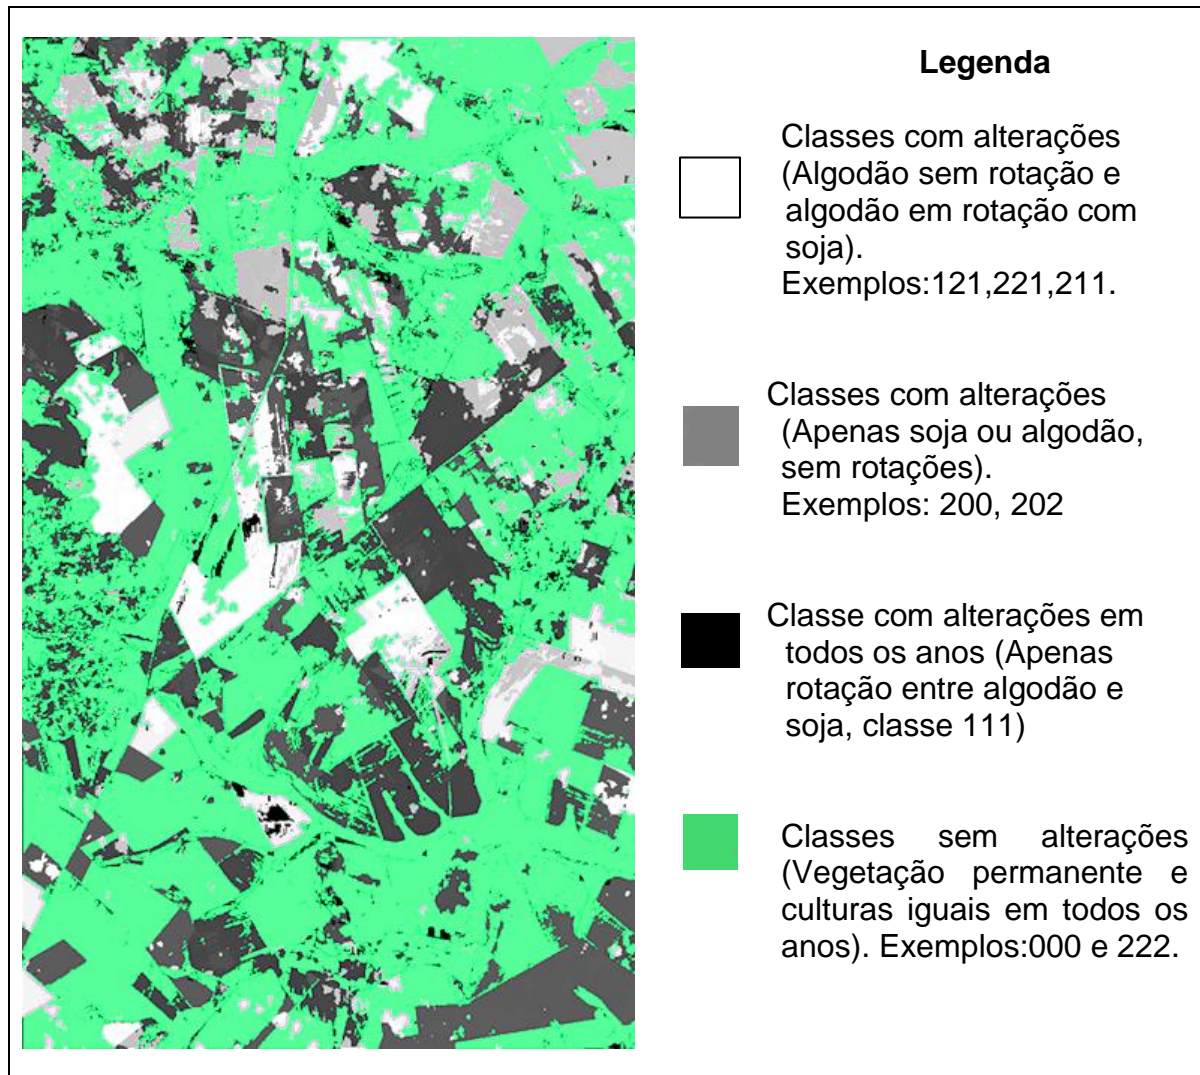
Classe codificada	Tipo de uso agrícola			Número de pixels
	2013	2014	2015	
121	Rotação	Algodão	Rotação	54.861
101	Rotação	Soja	Rotação	50.195
100	Rotação	Soja	Soja	46.643
102	Rotação	Soja	Algodão	42.671
221	Algodão	Algodão	Rotação	40.285
211	Algodão	Rotação	Rotação	31.034
202	Algodão	Soja	Algodão	29.441
112	Rotação	Rotação	Algodão	29.377

FONTE: o autor (2017).

Isto reflete corretamente as observações de campo, pois houve de fato uma substituição de campos de rotação (2013) por campos de soja em 2014. Partes destes campos, em 2015, foram novamente usados para cultivar algodão, sendo que para alguns casos com rotação.

É mostrada na FIGURA 33, para melhor exemplificar, a mesma cena da FIGURA 31 com as áreas sem rotação em verde. As demais áreas em tons de cinza e preto são aquelas que têm alterações para os três anos estudados.

FIGURA 33 – ÁREAS ONDE NÃO HOUVE ALTERAÇÕES (EM VERDE) E AQUELAS COM ALTERAÇÕES REPRESENTADAS POR SUAS CLASSES CODIFICADAS.



FONTE: o autor (2017).

6.5.3 Validação da análise de pós-classificação com a verdade de campo

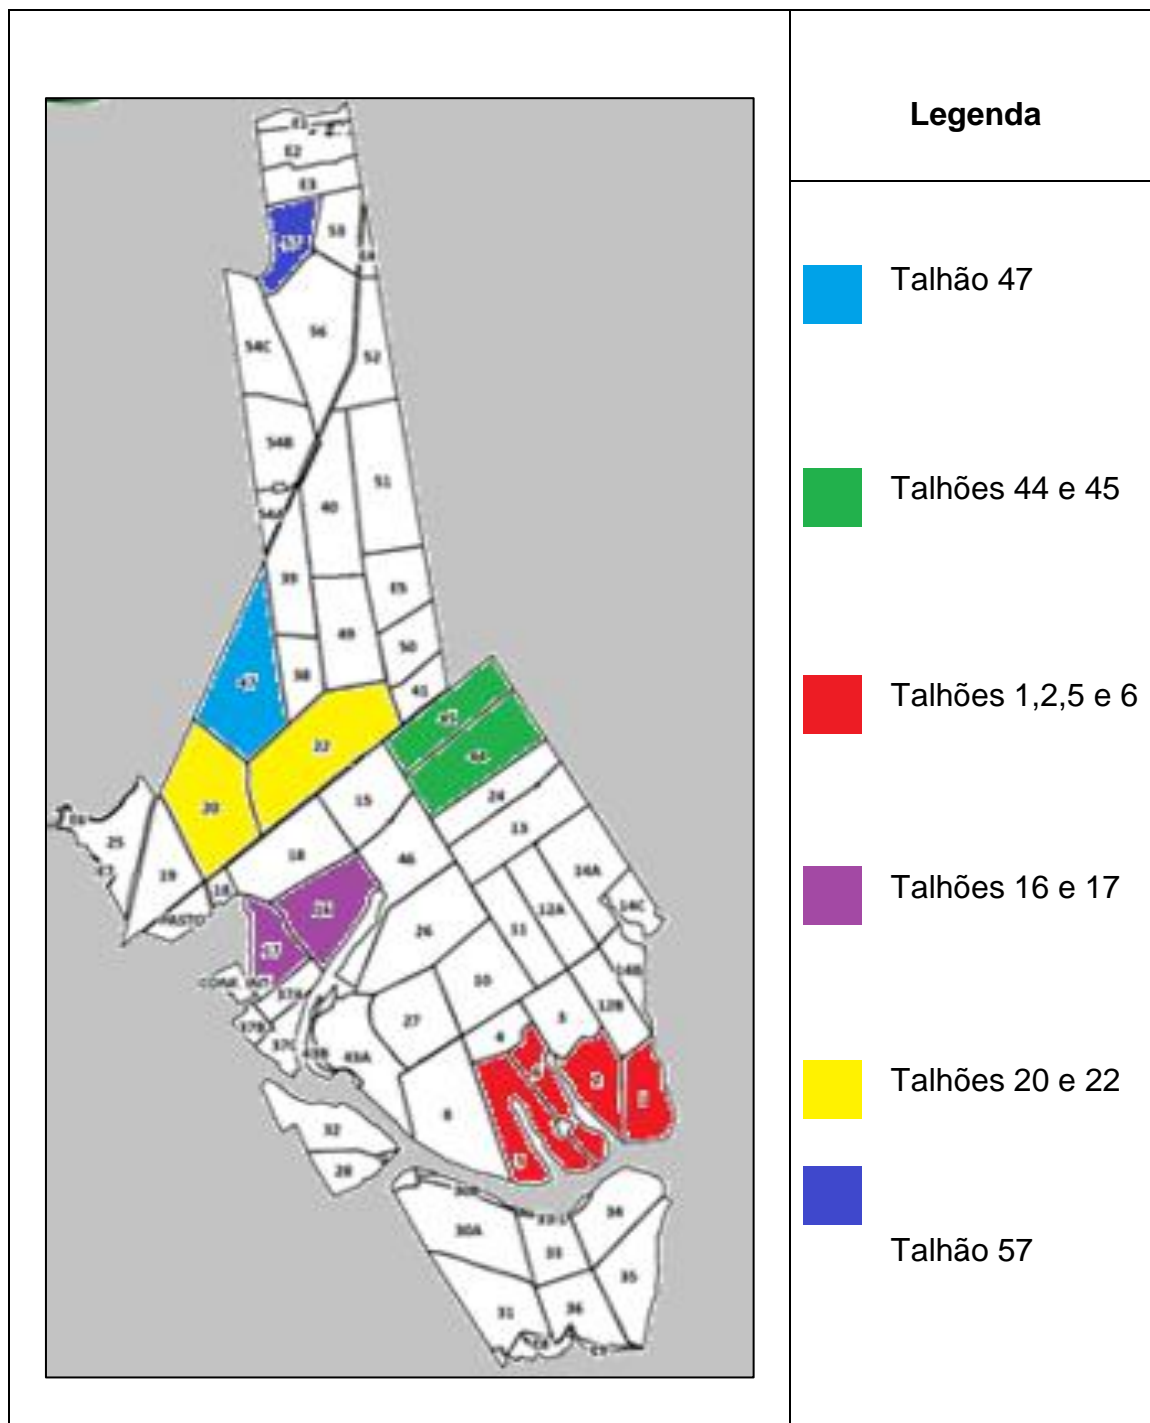
De acordo com os dados repassados pela propriedade é possível comparar a pós-classificação feita pelos dois métodos:

- a) Classificação Anual;
- b) Análise de Detecção das Mudanças Interanuais (ADMI).

Para isso foram escolhidos alguns talhões onde os limites são bem definidos nas imagens sendo possível localizar os mesmos e comparar a classificação do uso do solo feito em cada método. Na

FIGURA 34 é mostrada a localização dos talhões escolhidos como verdade de campo na Fazenda Marabá.

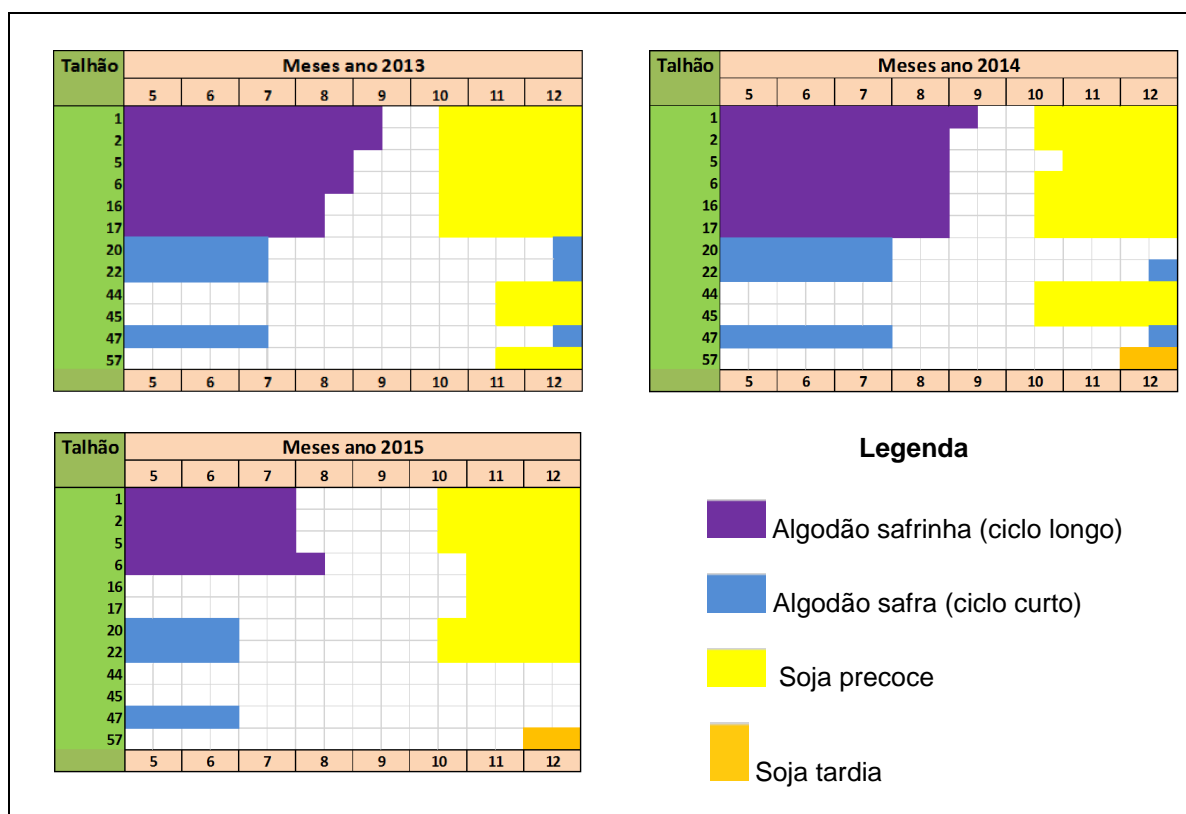
FIGURA 34 – LOCALIZAÇÃO DOS TALHÕES NA FAZENDA MARABÁ USADOS COMO VERDADE DE CAMPO PARA VALIDAÇÃO DOS MÉTODOS DE PÓS-CLASSIFICAÇÃO.



FONTE: o autor (2017).

Na FIGURA 35 é mostrada a distribuição de cada cultura ao longo dos oito meses estudados (maio a dezembro) para cada ano (2013 a 2015) nos talhões usados como verdade de campo. Foi adotado um fracionamento quinzenal dentro do mês para aproximar as datas de plantio e colheita de acordo com a realidade.

FIGURA 35 – DISTRIBUIÇÃO DAS CULTURAS EM CADA TALHÃO USADOS COMO VERDADE DE CAMPO PARA CADA ANO.



FONTE: o autor (2017).

O talhão 47 é cultivado com algodão sem rotação em todos os anos, sendo aquele que melhor representa a verdade de campo nos dois métodos de pós-classificação, pois não há alterações ao longo da série de classificação anual. Esse talhão pertence à variação 222 no método de detecções interanuais. Por se tratar de algodão safra (ciclo curto), é possível ver que na segunda quinzena do mês de dezembro dos anos de 2013 e 2014 há cultura no campo, mas não interfere na classificação, pois nessa fase vegetativa a planta ainda está no seu estágio inicial pós-emergência (V0), não sendo detectada como vegetação na imagem binária.

Os talhões 44 e 45 são classificados como soja sem rotação, ou seja, “sem alterações” (variação 000). Esses talhões são cultivados com soja sem rotação

apenas nos anos de 2013 e 2014, enquanto para o ano de 2015 a área não foi cultivada (pousio).

Para melhor demonstrar as análises é apresentado no QUADRO 4 os resultados por talhão e para cada tipo de pós-classificação. A determinação entre os acertos e erros foi feita através do cruzamento das informações obtidas junto à propriedade agrícola, em função do mês de plantio e colheita de cada cultura. Foi feita a comparação com a classificação obtida em cada método para cada mês, ano, talhão e cultura.

A classificação anual é representada pelo código M1 enquanto a classificação pela detecção das mudanças interanuais (ADMI) pelo código M2. A verdade de campo (VC) é apresentada pela mesma ordem dos tipos de variação na classificação multianual, ou seja, 0 para soja, 1 para rotação e 2 para algodão. Por exemplo 221, algodão em 2013 e 2014 e rotação em 2015. Para cada método são colocadas as variações obtidas em cada ano na ordem (2013 a 2015) para comparar com a verdade de campo. Para os talhões 44 e 45, o terceiro algarismo é substituído pela letra “x”, pois a área está sem cultura (pousio).

QUADRO 4 – COMPARAÇÃO DA VERDADE DE CAMPO COM OS RESULTADOS OBTIDOS NOS DOIS MÉTODOS DE PÓS CLASSIFICAÇÃO PARA CADA TALHÃO E O ACERTO PARA CADA MÉTODO.

Talhões	Verdade de campo	Variações encontradas pelos dois métodos		Acertos e erros das variações comparadas com a verdade de campo			
		M1 Classificação Anual	M2 Classificação “ADMI”	M1 Classificação Anual		M2 Classificação “ADMI”	
				Acertos	Erros	Acertos	Erros
47	222	222	222	3	0	3	0
44 e 45	00x	101	000	1	2	3	0
01, 02, 05 e 06	111	101	101	2	1	2	1
16 e 17	110	111	111	2	1	2	1
20 e 22	221	221	221	3	0	3	0
57	000	200	200	2	1	2	1
		Acurácia geral		72,2%		83,3%	

FONTE: o autor (2017).

Quando feita a validação para os quatro talhões agrupados no sul da área (talhões 01, 02, 05 e 06), a classificação “ADMI” (M2) mostra como alteração, embora em todos os anos essas áreas sejam cultivadas com rotação algodão/soja (variação 111), não havendo diferença no uso das áreas. Na classificação anual (M1) essas quatro áreas são corretamente apresentadas para os anos de 2013 e 2015, enquanto que para o ano de 2014 a mesma se mostrou incorreta pois indica soja sem rotação tardia.

Para os talhões 16 e 17, onde é praticada a rotação algodão/soja para os anos de 2013 e 2014 e soja sem rotação para 2015, ambos os métodos pós-classificação apresentaram erro para o ano de 2015. Para esses talhões a classificação “ADMI” (M2) apresenta como área sem alterações, o mesmo resultado que a classificação anual (M1) que atribui para todos os anos rotação.

Nos talhões 20 e 22, a classificação foi correta para os dois métodos analisados, apontando como áreas de alteração, pois a verdade de campo indica que nesses talhões nos anos de 2013 e 2014 foram cultivados algodão sem rotação e no ano de 2015 houve alteração para rotação algodão/soja.

O talhão 57 repete em todos os anos o mesmo uso (soja sem rotação) como verdade de campo. Os dois métodos erram a classificação apenas para o ano de 2013, confundindo com algodão sem rotação.

Os talhões melhores classificados são o 47, 20 e 22 onde o acerto é de 100% em todos os anos e para ambos os métodos de pós-classificação. Esse alto índice de acerto pode ser explicado, pois o algodão que é a cultura desses talhões, que apresenta o valor do nível de cinza baixo (primeiros meses do ano) e gera pouca confusão na classificação.

Para os talhões 44 e 45 apenas a classificação anual (M1) erra em dois anos (2013 e 2015). O resultado ainda é satisfatório para esses talhões, pois a classificação “ADMI” (M2) acerta na totalidade a pós-classificação.

No caso dos talhões 16 e 17, os dois métodos apresentam erros, mas apenas para o ano de 2015 em ambos.

O resultado da classificação para os talhões 01, 02, 05 e 06 pode ser avaliada apenas na classificação anual (M1), onde o acerto é de 67%, ou seja, apenas um ano é classificado de forma errada (2014).

Ao comparar os dois métodos de pós-classificação, considerando os talhões estudados, a classificação “ADMI” (M2) apresentou acurácia geral melhor, pois em

cada área erra apenas uma vez em cada série temporal, ou seja, no máximo uma por ano. A classificação anual (M1) apresentou uma acurácia geral menor em função de cometer erro para dois anos dentro de uma mesma série (talhões 44 e 45), onde errou para os anos de 2013 e 2015. Entretanto o acerto para esses talhões ficou em 67% na série pois a classificação “ADMI” (M2) compensou esse erro com acerto de 100%.

Com os resultados obtidos nos talhões de conferência da Fazenda Marabá é possível identificar as áreas correlatas em propriedades vizinhas que estão na cena, principalmente aquelas na porção sul e oeste das imagens.










6.6 ANÁLISE MULTIANUAL

Do processo de combinação das imagens multitemporais de cada ano, quando colocadas na sequência RGB com 2013 no canal “R”, 2014 no canal “G” e 2015 no canal “B”, tem-se uma composição colorida (multianual) que permite verificar as alterações ocorridas no período estudado. Dessa forma, tem-se a leitura dos valores na escala de 0 a 255 para cada pixel e de forma separada em cada canal para cada ano. Pode-se ver na FIGURA 36 as duas imagens (NDVI e SAVI) considerando os três anos de análise (2013 a 2015) para os meses de maio a dezembro em cada ano quando combinadas na composição colorida RGB.

Através da combinação dos números digitais presentes em cada canal da imagem multianual é possível fazer a interpretação do uso do solo para cada ano separadamente através dos valores obtidos na TABELA 11 que determina o valor dos pesos para cada mês em que há vegetação no campo.


No QUADRO 5 é apresentada uma legenda onde cada cor é gerada pela combinação das imagens multitemporais de cada ano, que indica uma classe de uso em função dos níveis digitais presentes nas imagens da FIGURA 36.

QUADRO 5 – CORES RESULTANTES DA COMBINAÇÃO RGB COM OS VALORES DO NÍVEL DE CINZA PARA CADA ANO E O RESPECTIVO USO DO SOLO.

Cor	Ano e ND			Uso do solo (classes)
	2013	2014	2015	
	1	6	132	Algodão sem rotação (2013 e 2014); Algodão em rotação com Soja tardia (2015).
	194	136	143	Algodão em rotação com Soja tardia (todos os anos).
	196	6	164	Algodão em rotação com Soja tardia (2013 e 2015); Algodão sem rotação (2014);
	136	144	144	Algodão em rotação com Soja tardia (todos os anos).
	1	164	3	Algodão sem rotação (2013 e 2015); Soja precoce sem rotação (2014).
	3	152	193	Algodão sem rotação (2013); Algodão em rotação com Soja tardia (2014); Soja tardia sem rotação (2015).
	207	31	34	Soja precoce sem rotação (2013); Algodão sem rotação (2014 e 2015);
	129	179	47	Soja precoce sem rotação (2013); Algodão em rotação com Soja tardia (2014); Algodão sem rotação (2015).
	255	255	255	Vegetação permanente.

FONTE: o autor (2017).

FIGURA 36. COMPARAÇÃO DAS IMAGENS MULTIANUAIS DOS ÍNDICES NDVI (IMAGEM “A”) E SAVI (IMAGEM “B”) COM A COMPOSIÇÃO DAS IMAGENS MULTITEMPORAIS NOS ANOS 2013 (R), 2014 (G) E 2015 (B).



FONTE: o autor (2017).

Na comparação das imagens NDVI (36A) e SAVI (36B), na FIGURA 36, é possível visualizar que o índice NDVI é superior para discriminar as áreas com vegetação permanente (nativa) onde o nível de cinza é igual a 255 quando comparada com o índice de vegetação SAVI que para as mesmas áreas (assinaladas em vermelho) apresenta valores digitais menores que 255.

6.6.1 Classificação da imagem multianual da imagem NDVI

As classes adotadas são as mesmas usadas nos dois métodos anteriores (item 6.5) o que possibilita a comparação entre os mesmos. Para as imagens multianuais foram empregados três métodos de classificação:

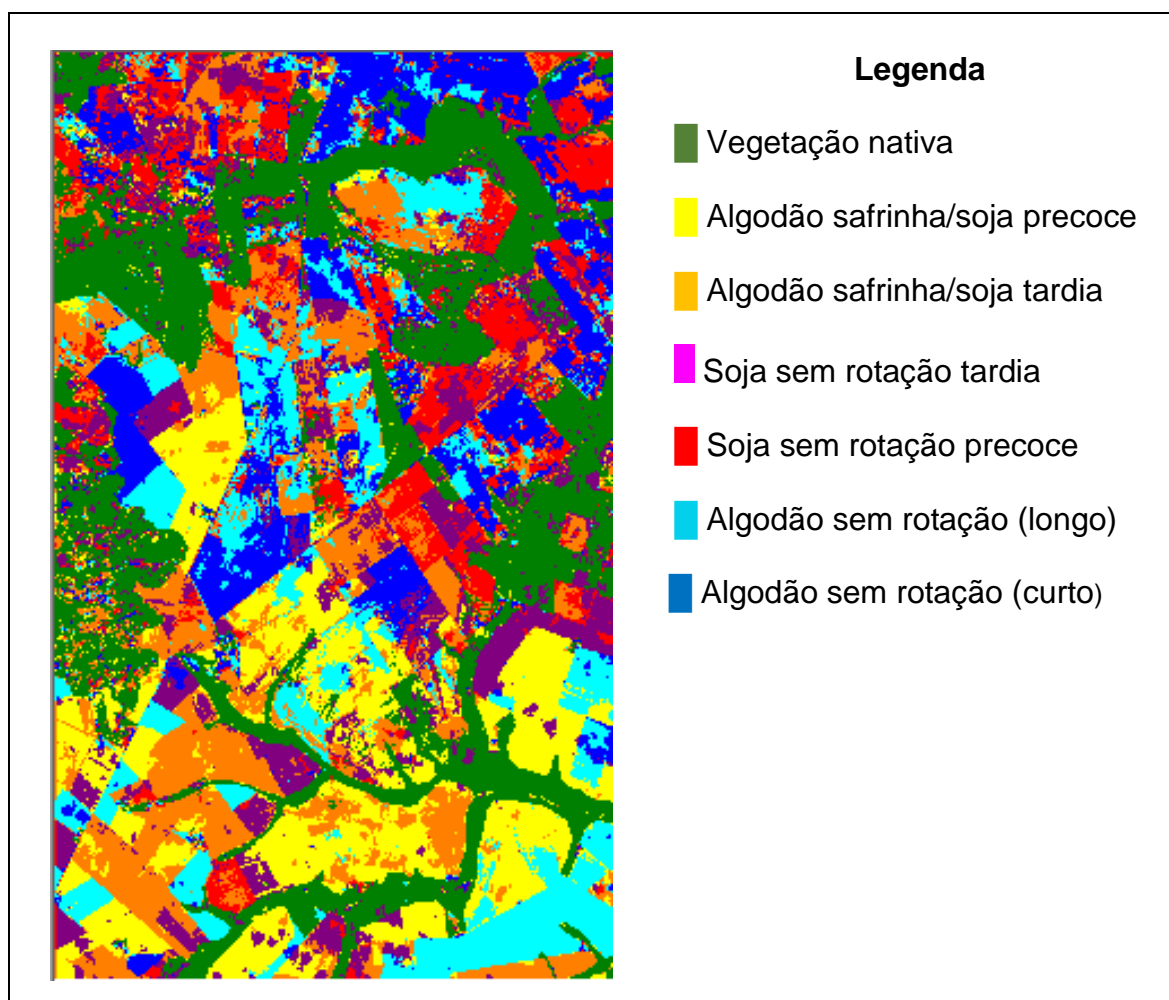
- a) Não-supervisionada (ISODATA, com Distância Mínima);

- b) Supervisionada com Mínima Distância Euclidiana e
- c) Supervisionada com Máxima Verossimilhança (MAXVER).

Foi possível fazer a classificação supervisionada na análise multianual, pois a imagem gerada é colorida o que facilita a interpretação do usuário, ao contrário das imagens na série anual (item 6.5.1) onde as imagens estão em tom cinza.

Na FIGURA 37 é mostrada a classificação não-supervisionada (ISODATA) da imagem multianual apenas para o índice NDVI, feita pelo Método da Mínima Distância Euclidiana.

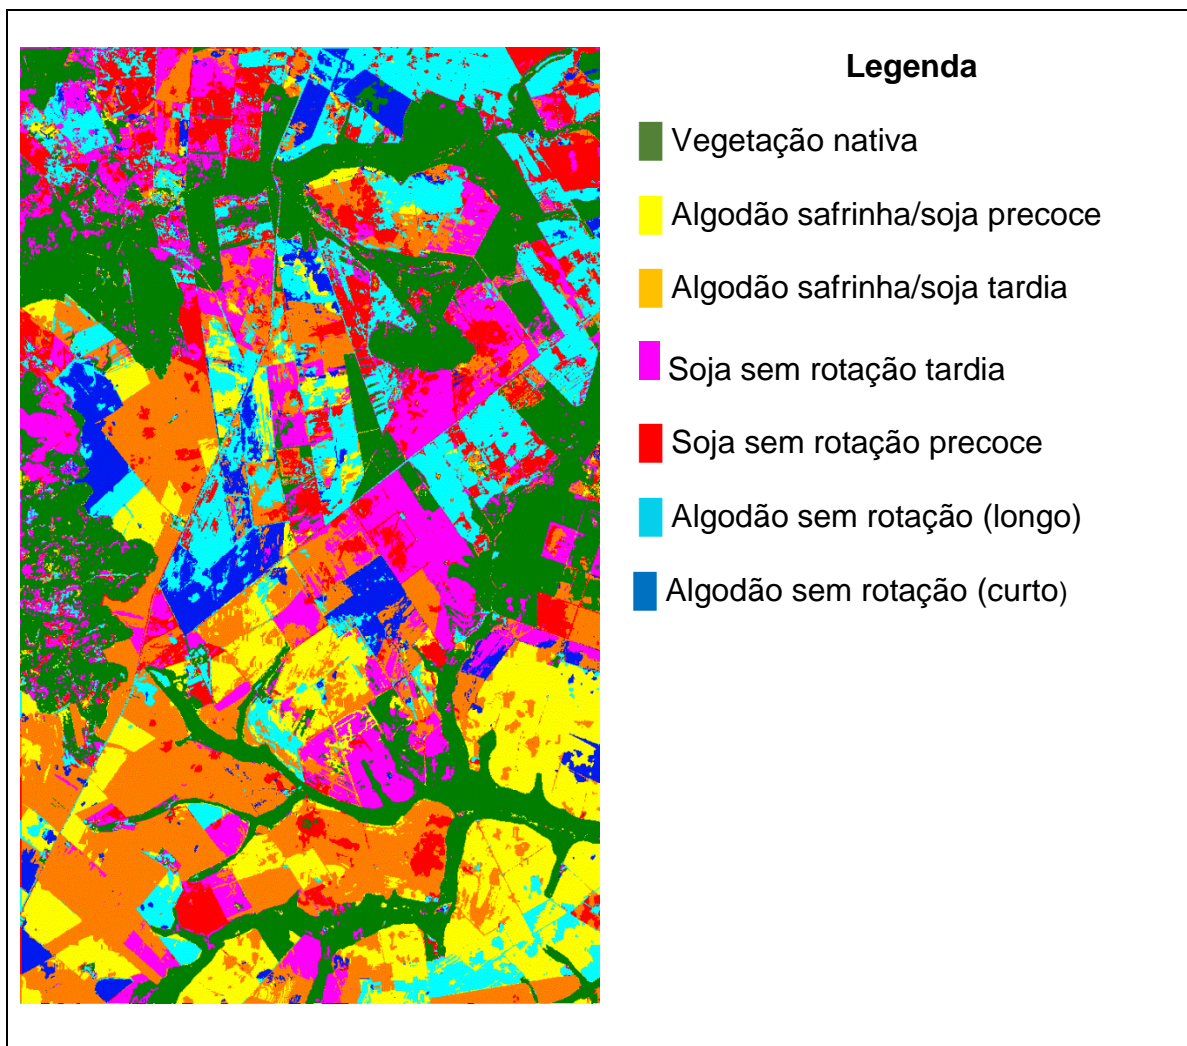
FIGURA 37- CLASSIFICAÇÃO NÃO-SUPERVISIONADA DA IMAGEM MULTIANUAL PELO MÉTODO CLUSTERS (ISODATA COM MÍNIMA DISTÂNCIA EUCLIDIANA).



FONTE: o autor (2017).

Na FIGURA 38 é mostrada a classificação supervisionada pelo método da Mínima Distância Euclidiana.

FIGURA 38 - CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM MULTIANUAL PELA MÍNIMA DISTÂNCIA EUCLIDIANA.



FONTE: o autor (2017).

Nas duas matrizes de confusão, (TABELA 22 e TABELA 23) as classes numeradas de 1 a 7, correspondem a:

- 1- Vegetação nativa;
- 2- Algodão sem rotação (ciclo curto);
- 3- Algodão sem rotação (ciclo longo);
- 4- Soja sem rotação tardia;
- 5- Soja sem rotação precoce;

6- Algodão safrinha / Soja precoce;

7- Algodão safrinha / Soja tardia.

A matriz de confusão da classificação supervisionada (Mínima Distância Euclidiana) é mostrada na TABELA 22.

TABELA 22 – MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM MULTIANUAL (MÍNIMA DISTÂNCIA EUCLIDIANA).

Classes	Total	Classes						
		1	2	3	4	5	6	7
1 Vegetação nativa	2591	2591	0	0	0	0	0	0
2 Algodão s/ rotação (curto)	1176	0	1176	0	0	0	0	0
3 Algodão s/ rotação (longo)	1262	0	3	1112	0	0	147	0
4 Soja s/ rotação (tardio)	1249	0	0	0	1247	2	0	0
5 Soja s/ rotação (precoce)	683	0	0	0	260	373	0	50
6 Algodão / Soja precoce	1593	0	0	32	162	0	1399	0
7 Algodão / Soja tardia	1411	0	0	0	0	4	2	1405
NÚMERO DE PIXELS	9965	2591	1179	1144	1669	379	1548	1455

Desempenho geral da classe **(9303 / 9965) = 93,4%**
Estatística Kappa = 92,0%

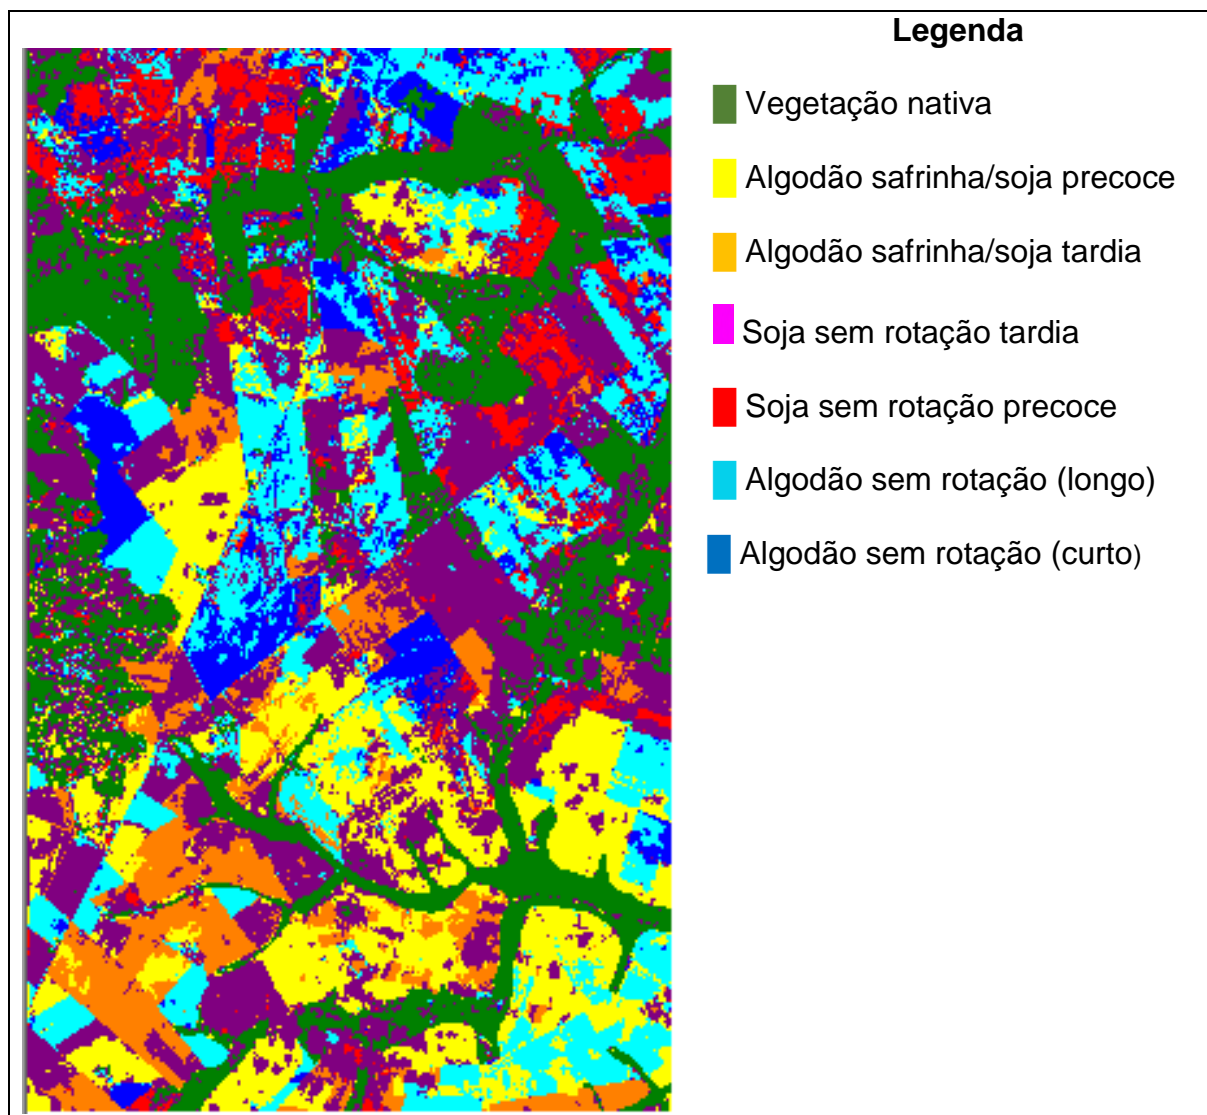
FONTE: o autor (2017).

A análise da TABELA 22 permite afirmar que a qualidade da classificação foi excelente. O resultado comprova que para as classes (1 e 2) vegetação nativa e algodão sem rotação ciclo curto a detecção é mais acurada devido às mesmas terem os valores digitais nos extremos da escala, 255 para a primeira e 1 a 7 para a segunda.

A classificação não-supervisionada e supervisionada para esse método (Mínima Distância) foram equivalentes quando observadas as imagens resultantes na FIGURA 37 e na FIGURA 38.

Na FIGURA 39 é mostrada a classificação supervisionada pelo método da Máxima Verossimilhança (MAXVER).

FIGURA 39 - CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM MULTIANUAL PELA MÁXIMA VEROSSIMILHANÇA (MAXVER)



FONTE: o autor (2017).

A matriz de confusão da classificação supervisionada (MAXVER) é mostrada na TABELA 23. Na mesma é possível ver que a classe vegetação nativa (classe 1) continua tendo a melhor acurácia. De posse do valor do índice Kappa (94,2%), verifica-se que a classificação é excelente e superior à classificação supervisionada pela Mínima Distância Euclidiana, como é de se esperar.

TABELA 23 – MATRIZ DE CONFUSÃO PARA A CLASSIFICAÇÃO SUPERVISIONADA DA IMAGEM MULTIANUAL (MAXVER).

Classes	Total	Classes						
		1	2	3	4	5	6	7
1 Vegetação nativa	2557	2557	0	0	0	0	0	0
2 Algodão s/ rotação (curto)	978	0	978	0	0	0	0	0
3 Algodão s/ rotação (longo)	1327	0	68	1112	0	0	147	0
4 Soja s/ rotação (tardio)	1926	33	133	32	1668	9	0	51
5 Soja s/ rotação (precoce)	370	0	0	0	0	370	0	0
6 Algodão / Soja precoce	1401	1	0	0	1	0	1399	0
7 Algodão / Soja tardia	1406	0	0	0	0	0	2	1404
TOTAL DE PIXELS	9965	2591	1179	1144	1669	379	1548	1455

Desempenho geral da classe **(9488 / 9965) = 95,2%**
Estatística Kappa = 94,2%

FONTE: o autor (2017).

6.6.2 Validação da classificação da análise multianual com a verdade de campo

Nessa etapa foram confrontados com a verdade de campo das análises de pós-classificação (Anual e Detecção das Mudanças Interanuais, “ADMI”). Os mesmos talhões, para se ter os mesmos critérios de avaliação.

No QUADRO 6 são apresentados os resultados da classificação multianual para cada talhão e para os três métodos de classificação. Os acertos são indicados como a letra “C” e os erros com a letra “I”. O valor em percentual obtido no final da análise é a relação entre o número de acertos e o número total de amostras (6 lotes no caso).

QUADRO 6 - COMPARAÇÃO DA VERDADE DE CAMPO COM OS RESULTADOS OBTIDOS NOS TRÊS MÉTODOS DE CLASSIFICAÇÃO DA ANÁLISE MULTIANUAL E O ACERTO PARA CADA TALHÃO. ONDE “C” É CORRETO E “I” É INCORRETO.

Talhões	Verdade de campo	Método de classificação		
		ISODATA Mínima Distância Euclidiana	Supervisionado Mínima Distância Euclidiana	Supervisionado MAXVER
47	Algodão sem rotação	C	C	C
44 e 45	Soja sem rotação	C	C	C
01, 02, 05 e 06	Rotação todos os anos	I	I	C
16 e 17	Rotação anos de 2013 e 2014 e soja sem rotação 2015	C	C	C
20 e 22	Rotação apenas em 2015	I	I	I
57	Soja sem rotação	I	I	C
Acurácia geral		50,0%	50,0%	83,3 %

FONTE: o autor (2017).

Para o talhão 47 a classificação foi adequada com o uso do solo para os três métodos, onde a área é ocupada por algodão sem rotação em todos os anos. Na análise dos talhões 44 e 45 todos os métodos de classificação também identificam a cultura correta na área, ou seja, soja sem rotação.

Os talhões 01, 02, 05 e 06, são classificados com soja sem rotação tardia, no método da Mínima Distância Euclidiana (supervisionado e não-supervisionado). Na classificação supervisionada MAXVER está correto, com pequenos pontos de confusão com soja sem rotação.

Para as áreas dos talhões 16 e 17, existe uma deficiência em todos os métodos, que apontam rotação na série dos três anos, mas não identificam para o último ano a cultura da soja sem rotação. A classificação foi considerada como correta, pois ao longo da série realmente existe rotação do uso da área.

Nos talhões 20 e 22 a classificação multianual aponta o uso do solo como algodão sem rotação, o que ocorre na realidade apenas nos anos de 2013 e 2014. Falha para o ano de 2015, pois nesse ano existe rotação.

O talhão 57 é classificado como rotação para toda a série, mas a verdade de campo indica soja sem rotação para todos os anos. Apenas o método supervisionado MAXVER acertou a classificação para essa área.

Na análise de acertos e erros para a classificação multianual, é possível concluir que para as áreas com algodão sem rotação não há erro de classificação (acerto de 100% das amostras no talhão 47). Isto pode ser explicado pelo valor baixo do nível de cinza que consegue separar melhor essa classe.

A cultura da soja sem rotação (talhões 44, 45 e 57), também apresenta um valor de acertos elevado (66,6%). Os únicos métodos de classificação que falham são da Mínima Distância Euclidiana (não-supervisionado e supervisionado).

Para as áreas dentro da série temporal com rotação o acerto sempre é menor, com exceção dos talhões, 01, 02, 05 e 06 onde o método MAXVER indica a classe correta. Como os valores são próximos para rotação e soja sem rotação, existe pouca acurácia em diferenciar essas classes. No caso do algodão sem rotação, como o valor do contador é baixo, não há superposição de classes.

6.7 COMPARAÇÃO DOS MÉTODOS

Comparando apenas os métodos de classificação não-supervisionados usados nas análises pós-classificação e multianual, aquele que melhor apresenta resultados quando confrontado com a verdade de campo é a Análise de Detecção das Mudanças Interanuais “ADMI”, seguido da classificação anual (multitemporal) e com os piores resultados a classificação multianual (ISODATA).

Na análise multianual o melhor método de classificação encontrado foi o supervisionado da Máxima Verossimilhança que é equivalente à análise “DMI”. Quando usada a classificação com Distância Mínima (supervisionado ou não-supervisionado) para a análise multianual, ambos têm o pior desempenho entre todos. No QUADRO 7 são mostrados os valores da acurácia geral de todos os métodos comparados nas duas modalidades de análise.

QUADRO 7 – VALOR EM PERCENTUAL DA ACURÁCIA GERAL DE CADA MÉTODO DE CLASSIFICAÇÃO TESTADO QUANDO CONFRONTADA COM A VERDADE DE CAMPO.

Tipo de análise	Método	Acurácia geral (%)
Pós-classificação	Classificação anual	72,2
	Classificação “ADMI”	83,3
Multianual	ISODATA com Distância Mínima	50,0
	Supervisionada com Distância Mínima	50,0
	Supervisionada com Máxima Verossimilhança	83,3

FONTE: o autor (2017).

Dessa forma é possível verificar que o uso da classificação não-supervisionada é compatível para a análise pós-classificação onde as imagens são classificadas ano a ano separadamente e os clusters gerados pelo algoritmo ISODATA, onde são identificadas as classes com uma acurácia muito boa quando comparadas com a verdade de campo. Essa é uma vantagem pois não é necessária uma coleta de amostras de treinamento o que agiliza a operação de análise.

Para a análise multianual, quando a imagem de entrada é uma composição colorida onde cada banda RGB corresponde a um ano, é preferível o uso da classificação supervisionada com Máxima Verossimilhança, que permite melhores resultados quando comparada com a verdade de campo.

Uma característica que deve ser mencionada é que quando comparados os dois métodos de classificação supervisionados, o que melhor apresentou índice Kappa foi o da Mínima Distância em relação ao da Máxima Verossimilhança, mas o primeiro é inferior para validar a verdade de campo.

A área que apresenta maior diferença na classificação quando comparados os três anos e a imagem multianual é aquela com soja sem rotação, seja precoce ou tardia. Essa característica pode ser explicada pois os valores de soja se confundem com as áreas de rotação já que a variação do nível de cinza para a soja varia de 96 a 224, que corresponde à maior amplitude entre as classes. Para rotação essa amplitude de nível de cinza é de apenas 70 níveis de cinza (129 a 199).

As áreas que apresentam maior confusão na classificação quando comparados os três anos são as áreas de rotação, pois além de existir duas culturas para um mesmo ano, o ciclo dessas pode ser diferente entre um ano e outro. No caso de áreas onde há rotação em um ano e culturas sem rotação em outro ano, a

classificação é melhor se feita pelo método “ADMI” conforme testado anteriormente, pois consegue separar bem essas áreas.

7. CONCLUSÕES

Nesta tese foi apresentado um método de análise multitemporal de imagens baseado na codificação binária de imagens do Índice de Vegetação por Diferença Normalizada (NDVI). A binarização foi feita com o método de Otsu. As imagens resultantes foram então classificadas com diferentes métodos para analisar as variações temporais.

O estudo comprovou que o uso de uma série longa de imagens LANDSAT permite obter informações em uma escala temporal para o emprego em áreas agrícolas e através do índice de vegetação NDVI possibilita o monitoramento das culturas de algodão e soja ou rotação das mesmas ao longo do ano ou em séries multianuais.

A limiarização das imagens, pelo Método Otsu, possibilitou uma padronização das mesmas para que a vegetação pudesse ser segmentada em um primeiro momento. Posteriormente as imagens de cada ano foram agrupadas em uma única imagem pela combinação de todas as datas permitindo a análise da dinâmica da vegetação, especialmente a agricultura. Para a área de estudo em particular, o índice NDVI se mostrou melhor que o SAVI na descrição da vegetação.

Com os resultados obtidos nas análises de pós-classificação e multianual, é possível afirmar que o algodão sem rotação, ciclo longo ou curto, é a cultura com maior índice de acerto na classificação, pois como ocorre nos primeiros meses da série anual, o valor do nível de cinza é sempre baixo.

Para a rotação algodão / soja ao longo da série anual, os valores do nível de cinza são um pouco maiores que para a cultura da soja sem rotação e têm pouca amplitude sendo dependente especialmente do ciclo do algodão.

A área de vegetação nativa (Mata ciliar e Cerrado) se comporta de forma equivalente nos dois métodos de classificação (análise pós-classificação e análise multianual) para todos os anos por ser a classe onde a acurácia da classificação é maior, pois o valor do contador digital é sempre alto (varia de 240 a 255).

Quando confrontados com a verdade de campo, o método que melhor apresentou resultados para classificar o índice de vegetação NDVI foi a Análise de Detecção de Mudanças Interanuais, ADMI, desenvolvida ao longo desse trabalho, pois permite diferenciar as classes com as alterações ao longo da série anual (2013 a 2015) para uma mesma área.

RECOMENDAÇÕES

Para estudos futuros relacionados a esse trabalho as seguintes sugestões são propostas como desdobramento do mesmo:

- a) Estudo de outras culturas principalmente aquelas relacionadas com a rotação com a soja como é o caso do milho, pois para cada tipo de cultura pode haver um valor do contador digital, variando em função da época de plantio e colheita, independente do mês do ano. Pode-se propor o início da série em outubro com valor 1 e final em maio do ano seguinte com o valor 128. Dessa forma em uma área com rotação soja e milho, são encontrados os valores para a alteração, onde soja deve apresentar ND baixo e milho ND alto;
- b) Estudo do comportamento das pastagens quanto ao déficit hídrico ao longo de um ano com análise da alteração do comportamento fenológico em meses secos na região de Mato Grosso (especialmente julho a setembro);
- c) Comparar outros índices de vegetação com o NDVI para testar qual é o mais eficiente e robusto na análise.

REFERENCIAS

ALLEN, R.; TASUMI, M.; TREZZA, R. **SEBAL - Surface Energy Balance Algorithm for Land** – Advanced Training and User's Manual – Idaho Implementation, version 1.0, 2002.

ALVAREZ FILHO, A. Botânica e desenvolvimento. In. SANTOS, O. S. (coord.) **A cultura da soja – 1**. Rio Grande do Sul, Santa Catarina, Paraná. Editora Globo, Rio de Janeiro, 1988.

ASHOK, P. **Survey on Change Detection in SAR Images**. International Journal of Computer Applications (0975 – 8887) National Conference on Emerging Trends in Computer Technology (NCETCT), 2014.

BATISTA, J. L. O. **Detecção de mudanças da cobertura e uso do solo a partir de índices espectrais de vegetação em ambiente semiárido: enfoque para o município de Teofilândia, Bahia**. 153p. Dissertação (Mestrado em Modelagem em Ciências da Terra e do Ambiente) – Universidade Estadual de Feira de Santana, 2011.

BAUMGARDNER, M. F.; SILVA, L. F.; BIEHL, L. L.; STONER, E. R. **Advances in Agronomy**. Elsevier, v. 38, p. 1-44, 1986.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. **Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors**. Remote Sensing of Environment. New York, v. 113, p. 893-903, 2009.

CHAVEZ Jr., P. S. **An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data**. Remote Sensing of Environment, New York, v.24, p.459-479, 1988.

CHAVEZ Jr., P. S. **Image-Based Atmospheric Corrections – Revisited and Improved**. Photogrammetric Engineering & Remote Sensing, v. 62, n. 9, p. 1025-1036, 1996

CHEN, C. H. **Image processing for remote sensing**. CRC Press Taylor & Francis Group, 2008.

CHUVIECO, E. **Fundamentos de teledetección espacial**, RIALP S.A., Madrid, 1990.

CIHLAR, J. **Land cover mapping of large areas from satellites: status and research priorities**. International Journal of Remote Sensing. v. 21, n. 6 e 7, p. 1093–1114. 2000.

COHEN, J. **A coefficient of agreement for nominal scales**. Educational Psychology Measurement, v. 20, n. 1, p. 37-46, 1960.

CONGALTON, R. G. **A review of assessing the accuracy of classifications of remotely sensed data.** Remote Sensing Environment, v. 37, p. 35-46, 1991.

COPPIN, P.; BAUER, M. **Digital change detection in forest ecosystems with remote sensing imagery,** Remote Sensing Review., vol. 13, p. 207–234, 1996.

COPPIN, P.; NACKAERTS, K.; LAMBIN. **Digital change detection methods in ecosystem monitoring: a review.** International Journal Remote Sensing, v. 25, n. 9, p. 1565-1596, 2004.

COPPIN P.; NACKAERTS K.; QUEEN L.; CARPENTER W. **Operational monitoring of green biomass change for forest management.** Photogrammetric Engineering and Remote Sensing, v.67 (5): p.603-612, 1999.

CORRÊA, J.C.; SHARMA, R.D. **Produtividade do algodoeiro herbáceo em plantio direto no Cerrado com rotação de culturas.** Pesquisa Agropecuária Brasileira, v.39, n.1, p.41-46, 2004.

COSTA, A.; PIRES, J.R; YAMAOKA, R.S. **Efeitos da rotação de culturas sobre o rendimento do algodoeiro.** In: Reunião Nacional do Algodão, 7, Seminário Sobre a Cultura do Algodão em Mato Grosso, 2, 1993, Cuiabá, MT. Resumos... Cuiabá: EMPAER-MT; Campina Grande: EMBRAPA-CNPA, p.201, 1993.

DAUGHTRY, C.S.T.; GALLO, K.P.; BIEHL, L.L.; KANEMASU, E.T.; ASRAR, G.; BLAD, B.L.; NORMAN, J.M.; GARDNER, B.R. **Spectral estimates of agronomic characteristics of crops.** Machine Processing of Remotely Sensed Data Symposium, 10, p. 348-356. Purdue University, West Lafayette, IN, 1984.

DEER, P., **Digital Change Detection Techniques in Remote Sensing.** Technical Report. Department of Defence, Australia, 52 p., 1999.

DEMATTE J. A. M.; SILVA M. L. S.; ROCHA G. C.; CARVALHO L. A.; FORMAGGIO A. R.; FIRME L. P. **Variações espectrais em solos submetidos à aplicação de torta de filtro.** Rev. Bras. Ciênc. Solo vol.29 no.3 Viçosa Maio/junho, 2005.

DERPSCH, R.; ROTH, C. H.; SIDIRAS, N.; KÖPKE, U. **Controle da erosão no Paraná, Brasil: sistemas de coberturas de solo, plantio direto e preparo conservacionista,** IAPAR, 1991.

EMBRAPA. **Algodão: o produtor pergunta, a Embrapa responde.** Embrapa Algodão, Brasília, DF: Embrapa Informação Tecnológica, 2004.

EMBRAPA, in: http://www.sat.cnpm.embrapa.br/conteudo/missao_lansdat.php, acesso em 03/02/2016.

EPIPHANIO, J. C. N.; GLERIANI, J. N.; FORMAGGIO, A. R.; RUDORFF, B. F. T. **Índices de vegetação na cultura do feijão.** Revista de Pesquisa Agropecuária Brasileira, v. 31, n. 6, p. 445-454, Brasília-DF, 1996.

FARIAS, J. R. B.; NEPOMUCENO, A. L.; NEUMAIER, N. **Ecofisiologia da soja**. Circular técnica n. 48, EMBRAPA Soja, Londrina-PR, 2007.

FELFILI, J.M.; SILVA JUNIOR, M.C. **A comparative study of cerrado (sensu stricto) vegetation of Central Brazil**. Journal of Tropical Ecology, v. 9, p. 277-289, 1993.

FORMAGGIO, A. R.; EPIPHANIO, J. C. N. **Características espectrais de culturas e rendimento agrícola**. São José dos Campos: INPE. 178 p., 1990.

FRANKLIN, S. E.; GILES, P. T. **Radiometric processing of aerial and satellite remote-sensing imagery**. Computer: & Geosciences v. 21, n. 3, p. 413-423, 1995.

GAO, Bo-Cai; HEIDEBRECHT, K. B.; GOETZ, A. F. H. **Derivation of scaled surface reflectances from AVIRIS data**. Remote Sensing of Environment, v. 44, n. 2-3, p. 165-178, 1993.

HUETE, A. R. **A Soil-adjusted vegetation index (SAVI)**. Remote Sensing of Environment, 25, p.295-309, 1988.

HUETE, A. R. **Extension of soil spectral to the satellite: atmosphere, geometric and sensor considerations**. Photo Interprétation, v. 34, n. 2, p. 101-114, 1996.

IBGE. **Introdução ao processamento digital de imagens**. Manuais Técnicos em Geociências, n. 9. IBGE - Primeira Divisão de Geociências do Nordeste, Rio de Janeiro, 2001.

IBGE - **Noções Básicas de Cartografia**. Disponível em <http://www.ibge.gov.br/home/geociencias/cartografia>. Acesso em: setembro de 2016.

JACKSON, R. D.; HUETE, A. R. **Interpreting vegetation indices**. Preventive Veterinary Medicine, v. 11, n. 3-4, p. 185-200, 1991.

JENSEN, J. R. **Geometric correction introductory digital image processing: a remote sensing perspective**. Upper Saddle River, NJ:Prentice Hall, 2005.

JIA, X.; RICHARDS, J. A. **Binary coding of imaging spectrometer data for fast spectral matching and classification**. Remote Sensing of Environment. 43, p. 47-53, 1993.

KAWAKUBO, F. S.; MORATO, R. G.; CORREIA JUNIOR, P. A.; LUCHIARI, A. **Caracterização atual do uso da terra e da cobertura vegetal na região da Terra Indígena Sangradouro/Volta Grande-Mato Grosso, Brasil**. Investigaciones geográficas (Mx), Instituto de Geografía Distrito Federal, México, n. 53, abril, 2004, pp. 27-38

KIEL, R. **Deteção de mudanças no uso e na cobertura do solo em uma série temporal de imagens da região da campanha do Rio Grande do Sul**. 203p. Dissertação (Mestrado em Sensoriamento Remoto), UFRGS, Porto Alegre, 2008.

KLINK, C. A.; MACHADO, R. B. **A conservação do Cerrado brasileiro.** Megadiversidade, v.1, n.1, Julho 2005.

LEDA, V. C.; SANTOS, J. E. O.; FILGUEIRAS, R.; NICOLETE, D. A. P.; ZIMBACK, C. R. L. **Índices de Vegetação na caracterização da bacia do Ribeirão da Prata, Lençóis Paulista – SP.** Revista Brasileira de Energias Renováveis, v.5, p. 125- 135, 2016.

LEE, H. L.; YIN, C. W.; WAI, S. C. **Evaluation of control points: distribution on distortions and geometric transformations for aerial images rectification.** Procedia Engineering, v. 41, p. 1002 –1008, 2012.

LOPES, F. M. **Um modelo perceptivo de limiarização de imagens digitais.** 115p. Dissertação (Mestrado em Informática) – UFPR, 2003.

LU, D. P.; MAUSEL, E.; BRONDIZIO; MORAN, E. **Change detection techniques.** International Journal Remote Sensing, v. 25, n. 12, p. 2365–2407, 2003.

MARQUES FILHO, O; VIEIRA NETO, H. **Processamento digital de imagens,** Rio de Janeiro: Brasport, 1999.

MARUR, C. J.; RUANO, O. **Escala do algodão: um sistema de referência para determinação de fases de crescimento e desenvolvimento do algodoeiro.** Informações Agrônomicas, n. 105 (março/2004), Encarte Técnico, Potafos. 2004.

MAS, J. F. **Monitoring land-cover changes: a comparison of change detection techniques.** International Journal. Remote Sensing, vol. 20, n. 1, p.139-152, 1999.

MASEK, J. G.; VERMOTE, E. F.; SALEOUS, N.; WOLFE, R.; HALL, E. F.; HUENNRICH, F. **A LANDSAT surface reflectance data set for North America, 1990–2000.** Geoscience and Remote Sensing Letters, 3, p. 68–72, 2006.

MOREIRA, R. C. **Influência do posicionamento e da largura de bandas de sensores remotos e dos efeitos atmosféricos na determinação de índices de vegetação.** 181p. Dissertação (Sensoriamento Remoto) – INPE, 2000.

NOVO, E. M. L. M. **Sensoriamento Remoto – princípios e aplicações.** 4ª Ed. Editora Edgard Blucher, São Paulo-SP, 2010.

OTSU, N. **A threshold selection method from gray-level histogram.** IEEE Transactions on Systems, Man, and Cybernetics, p. 62-66, 1979.

PONZONI F.J.; SHIMABUKURO, Y.E. **Sensoriamento remoto no estudo da vegetação.** São José dos Campos: Parêntese, 2009.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto no estudo da vegetação.** 2. ed. São Paulo: Oficina de Textos, 2012.

PORTILLO, J. E. **Sensoriamento remoto e SIG na análise da cotonicultura nos municípios de Campo Verde e Primavera do Leste – MT.** 131p. Dissertação (Mestrado em Sensoriamento Remoto) – INPE, 2008.

RADKE R.J.; ANDRA, S.; AL-KOFAHI, O.; ROYSAM B. **Image change detection algorithms: a systematic survey.** IEEE Trans Image Process. Mar;14(3):294-307, 2005.

RICHARDS, J.A. **Thematic mapping from multitemporal image data using the principal components transformation.** Remote Sensing Environment, v.16, p. 35-46, 1984.

RISSO, J.; RIZZI, R.; RUDORFF, B. F. T.; ADAMI, M.; SHIMABUKURO, Y. E.; FORMAGGIO, A. R.; EPIPHANIO, R. D. V. **Índices de vegetação MODIS aplicados na discriminação de áreas de soja.** Revista Pesquisa Agropecuária Brasileira, Brasília, v.47, n.9, p.1317-1326, 2012.

ROBERTS, D. A.; GREEN, R. O.; ADAMS, J. B. **Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS.** Remote Sensing of Environment, v. 62, n. 3, p. 223-240, 1997.

ROSENDO, J. dos S. **Índices de Vegetação e Monitoramento do uso do solo e cobertura vegetal na Bacia do rio Araguari -MG - utilizando dados do sensor Modis.** 130 p. Dissertação (Mestrado em Geografia e Gestão do Território) - Programa de Pós-Graduação em Geografia, Universidade Federal de Uberlândia, Uberlândia. 2005.

ROSOLEM, C. **Ecofisiologia e manejo da cultura do algodoeiro.** Informações Agrônomicas, n. 95 (setembro/2001), Encarte Técnico, Potafos. 2001.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. **Monitoring vegetation systems in the great plains with ERTS.** Washington: NASA, v.1, p.309-317, 1973.

SAHOO, P.K.; SOLTANI, S.; WONG, A. K.C. **A Survey of Thresholding Techniques.** Computer Vision, Graphics, and Image Processing, n. 41, p. 233-260, 1988.

SANO, S.M.; ALMEIDA, S.P.; RIBEIRO, J.F. **Cerrado: Ecologia e Flora.** Brasília, Embrapa Cerrados, 2008.

SECRETARIA DO ESTADO DE PLANEJAMENTO E COORDENAÇÃO GERAL (SEPLAN). **Projeto de Desenvolvimento Agroambiental do Estado de Mato Grosso (PRODEAGRO)** Mapas Temáticos. Escala 1: 1.500.000. Mato Grosso, 2001.

SILVA, G. B. S.; LOEBMANN, D. G. S. W; FOLHARINI, S. O.; NOGUEIRA, S. F.; VICENTE, L. E.; ANDRADE, R. G; FURTADO, A. L. S. **Procedimentos para correção geométrica de imagens de satélite.** Circular Técnica 18, EMBRAPA Monitoramento por Satélite, Campinas, 2012.

- SILVEIRA, E. M. O.; CARVALHO, L. M. T.; ACERBI JR, F. W.; MELLO, J. M. **The assessment of vegetation seasonal dynamics using multitemporal NDVI and EVI images derived from MODIS**. *Cerne*, Lavras, v. 14, n. 2, p. 177-184, 2008.
- SINGH, A. **Review Article Digital change detection techniques using remotelysensed data**. *International Journal of Remote Sensing*, 10(6), p. 989–1003, 1989.
- SULSOFT, **Guia do ENVI em Português**. Disponível em: <http://www.envi.com.br/>, Acesso em: 26/10/2015.
- THENKABAIL, P. S.; SMITH, R. B.; PAUW, E. D. **Hyperspectral vegetation indices and their relationships with agricultural crop characteristics**. *Remote Sensing of Environment*, v. 71, p. 158–182, 2000.
- USGS, *LANDSAT about project descriptions*, disponível em: <http://landsat.usgs.gov/>, acesso em: 26/10/2016.
- VERMOTE, E. F., EI SALEOUS, N., JUSTICE, C. O., KAUFMAN, Y. J., PRIVETTE, J. L., **Atmospheric correction of visible to middle-infrared EOS-MODIS data over land surfaces: Background, operational algorithm, and validation**. *Journal of Geophysical Research*, 102, p. 17131–17141, 1997.
- XIE, H.; HEIPKE, C.; LOHMANN, P.; SOERGEL, U.; TONG, X. **A new binary encoding algorithm for the simultaneous region-based classification of hyperspectral data and digital surfasse models**. *Photogrammetrie Fernekundung Geoinformation*, v. 1, 2011.
- WANG, Q.; ADIKU, S.; TENHUNEN, J.; GRANIER, A. **On the relationship of NDVI with leaf area index in a deciduous forest site**. *Remote Sensing of Environment*, v. 94, n.2, p.244-255, 2005.
- ZHU, Z.; WOODCOCK, C. E. **Continuous change detection and classification of land cover using all available LANDSAT data** *Remote Sensing of Environment*, n. 144, p. 152–171, 2014.